BS2000/OSD

Performance-Handbuch

Stand der Beschreibung:

BS2000/OSD-BC V8.0
OSD/XC V4.0
X2000 V5.1

alle S- und SX-Server, Business Server SQ100

Ausgabe November 2009

Kritik… Anregungen… Korrekturen…

Die Redaktion ist interessiert an Ihren Kommentaren zu diesem Handbuch. Ihre Rückmeldungen helfen uns, die Dokumentation zu optimieren und auf Ihre Wünsche und Bedürfnisse abzustimmen.

Sie können uns Ihre Kommentare per E-Mail an manuals@ts.fujitsu.com senden.

Zertifizierte Dokumentation nach DIN EN ISO 9001:2000

Um eine gleichbleibend hohe Qualität und Anwenderfreundlichkeit zu gewährleisten, wurde diese Dokumentation nach den Vorgaben eines Qualitätsmanagementsystems erstellt, welches die Forderungen der DIN EN ISO 9001:2000 erfüllt.

cognitas. Gesellschaft für Technik-Dokumentation mbH
www.cognitas.de

Copyright und Handelsmarken

Copyright © Fujitsu Technology Solutions GmbH 2009.

Alle Rechte vorbehalten.
Liefermöglichkeiten und technische Änderungen vorbehalten.

EMC$^{2®}$, Symmetrix®, CLARiiON CX, SRDF™, TimeFinder™, SnapView™, Enginuity™ und EMC ControlCenter™ sind Warenzeichen oder eingetragene Warenzeichen der Firma EMC^2 Corporation, Hopkinton/MA (USA).

Alle verwendeten Hard- und Softwarenamen sind Handelsnamen und/oder Warenzeichen der jeweiligen Hersteller.

Inhalt

1 Einleitung 11

1.1 Zielsetzung und Zielgruppen des Handbuches 12

1.2 Konzept des Handbuchs 12

1.3 Änderungen gegenüber dem Vorgänger-Handbuch 14

1.4 Darstellungsmittel 15

2 Leistungserwartungen aus Anwendersicht 17

2.1 Kenngrößen für die Beschreibung der Leistung eines IT-Systems 17

2.1.1 Online-Anwendung 18

2.1.2 Batch-Verarbeitung 21

2.2 Formulieren einer Leistungserwartung 22

3 Leistungsverhalten der Server 27

3.1 CPU 27
3.1.1 Relativer Performance Faktor (RPF) 27
3.1.2 Multiprozessor-Systeme 28
3.1.3 CPU-Leistung von SX-Servern 31
3.1.4 CPU-Leistung von SQ-Servern 33

3.2 CPU-naher Speicher 35
3.2.1 Hauptspeicher 35
3.2.2 Globalspeicher (GS) 36
3.2.3 Hauptspeicher auf SX-Servern 38
3.2.4 Hauptspeicher auf SQ-Servern 39

3.3 Ein-/Ausgabe 40
3.3.1 Ein-/Ausgabe auf S-Servern 40
3.3.1.1 Kanal Typ S 40
3.3.1.2 Kanal Typ FC 41
3.3.2 Ein-/Ausgabe auf SX-Servern 45
3.3.2.1 I/O-Prozessor (X2000) 45
3.3.2.2 FC-Anschluss 46
3.3.2.3 Kanal Typ S 46
3.3.2.4 Interne Platten 47
3.3.3 Ein-/Ausgabe auf SQ-Servern 48
3.3.3.1 I/O-Prozessoren (X2000) 48
3.3.3.2 SAS-Anschluss 49
3.3.3.3 FC-Anschluss 49

3.4 Migration 50
3.4.1 Migration von S-Servern auf SX-Server 51
3.4.2 Migration von S-Servern auf SQ-Server 53
3.4.3 Migration von SX-Servern auf SQ-Server 55

4 Leistungsverhalten der Peripherie 57

4.1 Eigenschaften von Plattenspeichersystemen 57
4.1.1 Komponenten von Plattenspeichersystemen 57
4.1.2 Konfigurierung von Plattenspeichersystemen 60
4.1.2.1 RAID-Level 61
4.1.2.2 Replikationsfunktionen der Plattenspeichersysteme 63
4.1.3 Konfigurierung in BS2000/OSD 66
4.1.4 Hochleistungssysteme 69
4.1.5 Lasttypen 71

4.2 Plattenspeichersysteme an S-Servern 73
4.2.1 Symmetrix DMX und V-Max am Kanal Typ FC 73
4.2.1.1 Durchsatz mit einem Task 73
4.2.1.2 Durchsatz mit bis zu vier Kanälen Typ FC 74
4.2.1.3 Hardware-Bedienzeiten 75
4.2.1.4 PAV und RAID-Level bei OLTP-Betrieb 77
4.2.2 Symmetrix 8000 am Kanal Typ S 81
4.2.2.1 RAID1 81
4.2.2.2 RAID5 85

4.3 Plattenspeichersysteme an SX- und SQ-Servern 86
4.3.1 FibreCAT CX 86
4.3.1.1 Durchsatz mit einem Task 86
4.3.1.2 Hardware-Bedienzeiten 87
4.3.1.3 Hochlast, Überlast 89
4.3.2 Symmetrix DMX, V-Max 91
4.3.2.1 Durchsatz mit einem Task 91
4.3.2.2 Hardware-Bedienzeiten 92

4.4 LAN-Anschluss 94
4.4.1 LAN-Anschluss für S-Server 95
4.4.2 LAN-Anschluss für SX-Server 101
4.4.3 LAN-Anschluss für SQ-Server 102
4.4.4 Hilfsmittel zur Leistungskontrolle 103

4.5 Dateiverschlüsselung 106
4.5.1 Ablauf beim Zugriff auf eine verschlüsselte Datei 107
4.5.2 Konfigurations-Empfehlungen für S-Server 108
4.5.3 Beispiele mit Performance-Auswirkungen 109

5 Datensicherung 111

5.1 Logische Datensicherung mit HSMS/ARCHIVE 113

5.2 Physikalische Datensicherung mit FDDRL 116

5.3 Performance-Maßnahmen im Sicherungsbetrieb (HSMS) 119

5.4 Komponenten bei der Datensicherung 123
5.4.1 BS2000-CPU 124
5.4.2 Anschluss an den Server 125
5.4.3 Bandspeichersysteme 126
5.4.4 Plattenspeichersysteme 131

5.5 Messergebnisse 133
5.5.1 HSMS/ARCHIVE 133
5.5.2 FDDRL 135

5.6 Empfehlungen 138

6 Performance-Aspekte bei VM2000-Betrieb 139

6.1 Verwaltung der CPU-Leistung mit VM2000 140
6.1.1 VM2000-Scheduling 140
6.1.2 VM-Gruppen 143
6.1.3 CPU-Pools 144

6.2 Hauptspeicher 146

6.3 Peripherie 147

6.4 Gastsystem-Planung 151
6.4.1 Anzahl und Multiprozessorgrad der VMs 151
6.4.2 Einstellung der CPU-Quoten 152

6.5 Systembetreuung im Gastsystem 154
6.5.1 Einstellung der Prioritäten 154
6.5.2 PCS unter VM2000 156
6.5.3 Gastsystem-Bedienung 157

6.6 Messwerkzeuge für VM2000 158

7 Leistungsverhalten der Software 159

7.1 Größe des Benutzeradressraums 161

7.2 Performance-Kriterien beim Einrichten von Dateien 163
7.2.1 Logische Betriebsarten von Platten 163
7.2.2 Beschleunigung der Katalogzugriffe mit SCA 168
7.2.3 Einsatz von SF-Pubsets 170
7.2.4 Einsatz von SM-Pubsets 171
7.2.5 Einrichten von Systemdateien 174
7.2.5.1 Dateikatalog (SF-Pubset) 175
7.2.5.2 Dateikatalog (SM-Pubset) 179
7.2.5.3 Seitenwechselbereiche 180
7.2.5.4 SYSEAM-Datei 185
7.2.5.5 Meldungsdateien 187
7.2.6 Einrichten von Anwenderdateien 192

7.3 Arbeiten mit HIPERFILEs 195
7.3.1 Caching-Modi 196
7.3.2 ADM-PFA-Caching 199
7.3.3 User-PFA-Caching 203
7.3.4 Platten-Emulation (GS-Volumes) im Globalspeicher 207

7.4 Transaktionsbetrieb und BCAM 208
7.4.1 Phasen einer OLTP-Transaktion 208
7.4.2 Optimierung der einzelnen Phasen 210

8 Systemsteuerung 217

8.1 Job-Management 217
8.1.1 Job-Klassen 217
8.1.2 Job-Streams 221

8.2 Task-Management 223
8.2.1 Einführung in das PRIOR-Konzept 223
8.2.1.1 Task-Kategorien 224
8.2.1.2 Task-Prioritäten 226
8.2.1.3 Lastanalyse 229
8.2.1.4 Einstellen der Kategorieparameter 232
8.2.1.5 Prioritätenvergabe 240
8.2.1.6 I/O-Prioritäten-Steuerung für Tasks mit IORM 242
8.2.2 Einführung in das PCS-Konzept 243
8.2.3 Einführung in das TANGRAM-Konzept 254

8.3 Data-Management 257

9 Systeminterne Abläufe 259

9.1 Unterbrechungsanalyse (Funktionszustände) 259

9.2 Erzeugen und Beenden von Tasks 263

9.3 Verwalten der Betriebsmittel Hauptspeicher und CPU 265
9.3.1 Hauptspeicher-Verwaltung 267
9.3.2 CPU-Verwaltung 279

9.4 Steuern der Tasks über Warteschlangen 282

9.5 Ablauf einer Ein-/Ausgabe 286
9.5.1 Ein-/Ausgaben auf Platten 286
9.5.2 Hardware-Bedienzeit 289
9.5.3 Software-Bedienzeit 289

10 Einsatz des Mess-Systems openSM2 . . . 293

10.1 Messmonitor SM2 . . . 294

10.2 Routinemäßige Systemüberwachung . . . 296
10.2.1 Parameter für die Messung und Auswertung . . . 296
10.2.2 Bewertung charakteristischer Reports . . . 297
10.2.3 Anmerkung zu verschiedenen Reports . . . 298

10.3 Durchführung einer Engpass-Analyse . . . 303
10.3.1 Prinzipielle Vorgehensweise . . . 303
10.3.1.1 Parameter für die Messung und Auswertung . . . 305
10.3.1.2 Messwerte für die Untersuchung von systemorientierten Leistungsproblemen . . . 306
10.3.1.3 Messwerte für die Untersuchung von anwenderorientierten Leistungsproblemen . 307
10.3.1.4 Auswertung einer SM2-Messung . . . 310
10.3.2 Untersuchen eines systemorientierten Leistungsproblems . . . 311
10.3.2.1 Auslastung der Ein-/Ausgabe-Peripherie . . . 312
10.3.2.2 Paging-Aktivitäten . . . 319
10.3.2.3 CPU-Auslastung . . . 320
10.3.3 Untersuchen eines anwenderorientierten Leistungsproblems . . . 326
10.3.3.1 Task-Belegungszeit . . . 327
10.3.3.2 Behinderungen durch andere Tasks . . . 328
10.3.3.3 Hoher Betriebsmittelbedarf . . . 330
10.3.4 Einfluss des Netzes . . . 331

10.4 Leistungsbedarf von SM2 . . . 333

10.5 Weitere Hilfsmittel zur Performance-Analyse . . . 334
10.5.1 COSMOS . . . 334
10.5.2 COPE (Computer Performance Evaluator) . . . 335

11 Optimierungshinweise zur Erstellung von Anwender-Software 337

11.1 Wahl der Zugriffsmethode 337

11.2 Wahl des Bearbeitungsmodus 343
11.2.1 OPEN 343
11.2.2 Zugriffe 344
11.2.3 CLOSE 344

11.3 Performantes Laden von Programmen/Produkten 345
11.3.1 Prinzipieller Ablauf beim Binden/Laden eines Programms/Produkts 346
11.3.2 Allgemeine Hinweise zur Beschleunigung des Ladevorganges 347
11.3.3 Strukturelle Maßnahmen zur Reduzierung des Betriebsmittelbedarfs 349
11.3.4 Beschleunigung des Ladevorganges von C-Programmen 352
11.3.5 Nutzung von DAB 352

12 Anhang 353

12.1 Richtwerte für die BS2000/OSD-Server 353

12.2 Performance-relevante Systemparameter 362

12.3 Puffergröße der CISC-Firmware 374

Abbildungen 377

Literatur 379

Stichwörter 383

1 Einleitung

Das Ziel jeder IT-Abteilung ist die Erfüllung der Anforderungen der Systemanwender bei gleichzeitiger Minimierung der Kosten.

Die stetig steigende Zunahme

- der Realzeitverarbeitung mit allen Möglichkeiten der direkten Abwicklung von Kundenservice und Sachbearbeitertätigkeit,
- der Funktionen (Datennetze, Verteilte Verarbeitung),
- der Wechselbeziehungen zwischen diesen Funktionen
  (als Folge funktioneller Abhängigkeiten)

sowie die Berücksichtigung des Wachstums bestehender Anwendungen durch Ausweitung des Geschäftsvolumens, neuer Anwendungen und der Lastschwankungen des täglichen Betriebes machen die Anpassung der Systemumgebung (Hard- und Software) zu einem dynamischen Prozess.

Zur Sicherstellung eines wirtschaftlichen Systemeinsatzes sollte folgende Vorgehensweise angestrebt werden:

1. Festlegung der Leistungserwartungen.
2. Auslegung der Konfiguration.
3. Nach Aufnahme des Produktionsbetriebes **Durchführen von Messungen** zur Feststellung, ob die Leistungserwartungen erfüllt werden.
4. Bei Nichterfüllung der Leistungserwartungen Konzentration auf jene Engpässe, deren Beseitigung die größtmögliche Leistungsverbesserung verspricht.
5. Nach Beseitigung der festgestellten Engpässe **Wiederholung der Messungen**, denn öfter werden nach Eingriffen andere, bislang versteckte Engpässe sichtbar.
6. Auch nach Erfüllung der Leistungserwartungen ist die **periodische Durchführung von Messungen** erforderlich, denn nur so können sich abzeichnende Sättigungserscheinungen in den Hauptbetriebsmitteln durch wachsende Belastung erkannt und kritische Systemzustände vermieden werden.

1.1 Zielsetzung und Zielgruppen des Handbuches

Das Performance-Handbuch soll dem Systemanwender helfen, die Leistung seines IT-Systems zu beurteilen bzw. zu verbessern. Es wendet sich im besonderen an die Mitarbeiter im Data Center und in der Systembetreuung.
Hinweise für das Tuning von Konfiguration und Software sollen den wirtschaftlichen Einsatz von BS2000/OSD erleichtern.

Das vorliegende Performance-Handbuch ist Bestandteil der Basisliteratur zu BS2000/OSD-BC und damit auch von OSD/XC. In ihm werden die Performance-Aspekte des IT-Betriebs für die BS2000/OSD-Server übersichtlich zusammengefasst.

1.2 Konzept des Handbuchs

Das Handbuch beschreibt die Möglichkeiten für das Tuning von Konfiguration und Software zur Erfüllung der Leistungserwartungen und zur Optimierung des Betriebsmitteleinsatzes. Wenn erforderlich wird zwischen den einzelnen BS2000/OSD-Servern unterschieden.

Das Handbuch gibt **keine** Einführung in die Anwendung von Business Servern.
Diese Themen sind Gegenstand der Basisliteratur der Hardware, des Betriebssystems und der systemnahen Software-Produkte in der aktuellen Version.

Das Kapitel „Leistungserwartungen aus Anwendersicht“ beschreibt die für die Leistungsbeurteilung eines IT-Systems maßgebenden Größen und ihre Bedeutung.

Die Kapitel „Leistungsverhalten der Server“ und „Leistungsverhalten der Peripherie“ beschreiben die Bedeutung der Leistungskennzahl RPF (Relativer Performance Faktor) für die CPU-Leistung und das Leistungsverhalten der Ein-/Ausgabe-Peripherie. Anhand von Richtwerten geben die Kapitel Hinweise zur Auslegung der Ein-/Ausgabe-Konfiguration.

Die Kapitel „Datensicherung“, „Performance-Aspekte bei VM2000-Betrieb“ und „Leistungsverhalten der Software“ beschreiben performance-relevante Besonderheiten, die beim Einsatz der BS2000-Softwareprodukte zu beachten sind.

Die Kapitel „Systemsteuerung“ und „Systeminterne Abläufe“ erläutern den Einfluss von Systemparametern auf den Systemdurchsatz und beschreiben innere Vorgänge in BS2000/OSD, soweit sie zum Verständnis und zur Erleichterung der Interpretation von Messwerten beitragen.

Das Kapitel „Einsatz des Mess-Systems openSM2“ gibt Empfehlungen für die Parametereinstellung bei der Durchführung von Routine-Überwachungen und Engpass-Analysen, erläutert charakteristische Reports und beschreibt die prinzipielle Vorgehensweise bei der Untersuchung eines system- bzw. anwenderorientierten Leistungsproblems.

Das Kapitel „Optimierungshinweise zur Erstellung von Anwender-Software“ gibt Empfehlungen zur Wahl der Dateizugriffsmethode und -struktur und liefert Hinweise für das performante Laden von Programmen/Produkten.

Am Ende des Handbuches finden Sie einen Anhang sowie verschiedene Verzeichnisse, die Ihnen das Arbeiten mit diesem Handbuch erleichtern.

Readme-Dateien

Funktionelle Änderungen und Nachträge entnehmen Sie ggf. der Readme-Datei zu BS2000/OSD-BC oder den produktspezifischen Readme-Dateien der jeweiligen Softwareprodukte:

```
SYSRME.<product>.<version>.D
```

Beispiele

```
SYSRME.BS2CP.170.D (BS2000/OSD-BC V8.0)
SYSRME.PERCON.029.D (PERCON V2.9)
```

Die Benutzerkennung, unter der sich die gewünschte Readme-Datei befindet, erfahren Sie bei Ihrer zuständigen Systembetreuung. Den Pfadnamen der Readme-Datei erhalten Sie auch direkt über IMON mit folgendem Kommando:

```
/SHOW-INSTALLATION-PATH INSTALLATION-UNIT=<product>, LOGICAL-ID=SYSRME.D
```

Die Readme-Datei können Sie mit `/SHOW-FILE` oder in einem Editor lesen oder mit folgendem Kommando auf einem Standarddrucker ausdrucken:

```
/PRINT-DOCUMENT $<userid>.SYSRME.<product>.<version>.D,
                LINE-SPACING=*BY-EBCDIC-CONTROL
```

1.3 Änderungen gegenüber dem Vorgänger-Handbuch

Das vorliegende Handbuch enthält gegenüber dem Vorgängerhandbuch die nachfolgenden wesentlichen Änderungen:

- Das Handbuch wurde an BS2000/OSD V8.0 angepasst.

  Die Neuerungen von BS2000/OSD V8.0 finden Sie in den entsprechenden Vertriebsschriften und in der Freigabemitteilung von BS2000/OSD-BC (Produkt `BS2CP`, Version `170`) unter *http://manuals.ts.fujitsu.com*.
- Neuer Business Server: SQ100 (x86-Architektur).
- Neue Plattenspeichersysteme: Symmetrix DMX-4 und V-Max, FibreCAT CX4.
- Neues Bandlaufwerk: LTO-4.
- Neues RAID-Level: RAID6.
- Neue Software: FDDRL V17.0, HSMS V9.0, openNet-Server V3.3.
- Performance-Verbesserungen bei `/COPY-FILE`.

1.4 Darstellungsmittel

Wegen der häufigen Nennung der Bezeichnungen, werden der Einfachheit und Übersichtlichkeit halber folgende Abkürzungen gebraucht:

- **S-Server** für die Business Server der S-Serie
- **SX-Server** für die Business Server der SX-Serie
- **SQ-Server** für die Business Server der SQ-Serie (derzeit SQ100)
- **BS2000** für das Betriebssystem BS2000/OSD
- **SM2** für das Mess-System openSM2, sofern **keine** Unterscheidung zwischen dem Mess-System openSM2 und dem Messmonitor SM2 gemacht werden muss

In diesem Handbuch werden folgende Darstellungsmittel verwendet:

i für Hinweise auf besonders wichtige Informationen

[ ] Literaturhinweise werden im Text in Kurztiteln angegeben. Der vollständige Titel jeder Druckschrift, auf die durch eine Nummer verwiesen wird, ist im Literaturverzeichnis hinter der entsprechenden Nummer aufgeführt.

Kommandos, auf die in diesem Handbuch verwiesen wird, sind im Handbuch „Kommandos“ [16], die genannten Makros im Handbuch „DVS-Makros“ [9] beschrieben. Die Metasyntax der Kommandos bzw. Makros ist in den entsprechenden Handbüchern enthalten.

Hinweis zu den verwendeten Maßeinheiten

Im Handbuch werden die deutsche und die englische Schreibweise nebeneinander verwendet. Für Durchsatz und Übertragungsrate wird jedoch immer die Schreibweise Kbyte, Mbyte bzw. Gbyte verwendet. Es bedeuten:

1 KB	$= 2^{10}$ Bytes	= 1.024 Bytes	1 Kbyte	$= 10^{3}$ Bytes	= 1.000 Bytes
1 MB	$= 2^{20}$ Bytes	= 1.048.576 Bytes	1 Mbyte	$= 10^{6}$ Bytes	= 1.000.000 Bytes
1 GB	$= 2^{30}$ Bytes	= 1.073.741.824 Bytes	1 Gbyte	$= 10^{9}$ Bytes	= 1.000.000.000 Bytes

2 Leistungserwartungen aus Anwendersicht

2.1 Kenngrößen für die Beschreibung der Leistung eines IT-Systems

Jedes IT-System kann in folgende Ebenen hierarchisch untergliedert werden:

- Anwenderprogramme
- Systemsoftware
- Hardware

Die Anwenderanforderungen – repräsentiert durch die Anwenderprogramme – werden auf der Systemsoftware-Ebene in Tasks, auf der Hardware-Ebene in Befehle und Ein-/Ausgabe-Operationen umgewandelt.

Die Systemsoftware sieht nicht mehr die Anwenderprogramme als Belastung, sondern die Menge der simultan ablaufenden Tasks, welche unterschiedliche Anforderungen stellen.

Auf Hardware-Ebene erscheint die Belastung als eine Menge von Befehlen, Ein-/Ausgabe-Operationen und Speicherbelegungen, wobei viele verschiedene Belastungen auf der Anwenderebene zu derselben Hardwarebelastung führen können.

Für den Anwender stehen bei der Leistungsbewertung eines IT-Systems folgende Fragen im Vordergrund:

- Innerhalb welcher Zeit bearbeitet das IT-System die Anwenderanforderungen?
- Wieviele Anforderungen pro Zeiteinheit kann das IT-System abwickeln?

Die Leistungsfähigkeit auf Hardware-Ebene (z.B. Anzahl Befehle pro Sekunde) oder auf Systemsoftware-Ebene (z.B. Effizienz des Task-Managements in Form von Warteschlangentransfers pro Sekunde) berührt den Anwender erst in zweiter Linie. Die Anwendersoftware beeinflusst diese Leistungsfähigkeit durch ihr Verhalten. Deshalb kann man die Betrachtung dieser Komponenten nicht ganz vernachlässigen.

Abhängig von der Art der Anwendung (Online-Anwendung, Batch-Verarbeitung) werden für die **Leistungsbeschreibung auf Anwenderebene** die nachfolgend beschriebenen Kenngrößen verwendet.

2.1.1 Online-Anwendung

Sowohl beim Transaktions-, als auch beim Dialogbetrieb ist die Einheit der IT-Arbeit die **Transaktion**. Die Anwenderanforderungen in Form der Eingaben werden im System durch Transaktionen repräsentiert.

Beim **TP-Betrieb (**Transaktionsbetrieb) kann der Terminalbenutzer nur mit Programmen kommunizieren, die seitens der Anwendung fest vorgegeben sind. Üblicherweise arbeiten viele Terminalbenutzer mit einer relativ geringen Anzahl von **Anwenderprogrammen** zusammen.

Beim **Dialogbetrieb** formuliert jeder Terminalbenutzer seine eigene Anwendung, mit der er im Dialog die gewünschte Aufgabe abarbeitet. Die Programme, welche die jeweilige Dialoganwendung steuern, sind i.d.R. **Systemprogramme** zum Erstellen, Testen und Ändern von Dateien bzw. Programmen.

Die Zeit zwischen der Eingabe des Benutzers und der Fertigmeldung des Systems wird als **Transaktionszeit** bezeichnet. Sie kann sich aus mehreren Antworten mit unterschiedlicher Antwortzeit zusammensetzen.

Kenngrößen bei Online-Anwendung

- Transaktionsrate:
  Gesamtheit der erfolgreich beendeten Transaktionen pro Zeiteinheit
- Antwortzeit:
  Zeit **einer** Bearbeitung durch den Server
- Anzahl der Terminals
  (gleichbedeutend mit der Anzahl aktiver Terminalbenutzer)
- Wirkungsgrad pro Terminal

Darstellung der Zeitdefinitionen

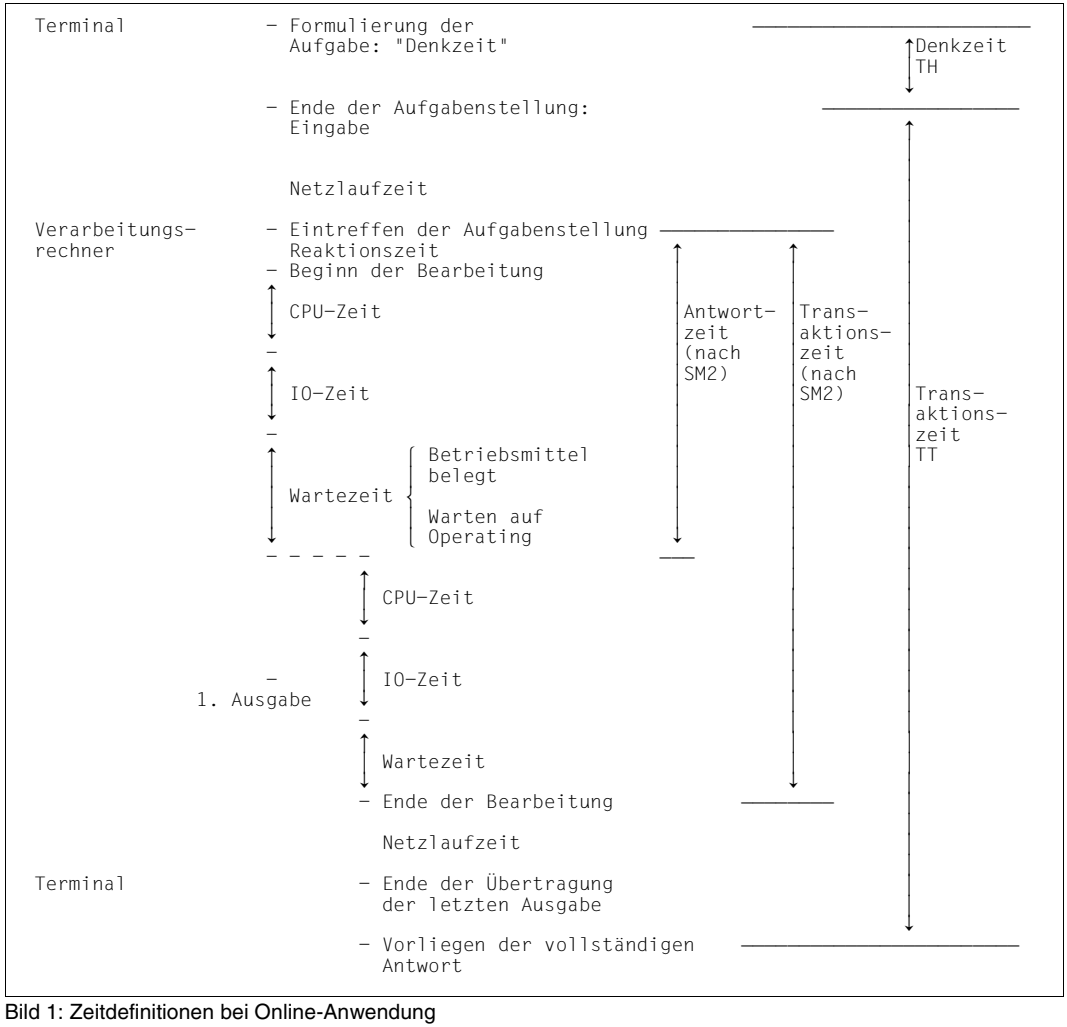

Bild 1: Zeitdefinitionen bei Online-Anwendung

Gibt es zu einer Transaktion nur **eine** Antwort (bei TP-Betrieb ist dies der Normalfall), so ist die Antwortzeit gleich der Transaktionszeit.

Die dargestellten Zeitdefinitionen (Antwortzeit, Transaktionszeit, Denkzeit) und die Transaktionsrate können durch das SM2-Messprogramm BCAM-CONNECTION erfasst werden, jedoch nur für Anwendungen, die mit dem Transportsystem BCAM über die Programmschnittstelle IDCAM oder ITIAM zusammenarbeiten.

Bei Anwendungen, die mit dem Transportsystem BCAM über die Programmschnittstelle SOCKETS zusammenarbeiten, liefert das SM2-Messprogramm BCAM-CONNECTION verbindungsspezifische Werte über PORT-Nummern:

- INPROC:
  Zeit vom Eintreffen einer Nachricht bei BCAM bis zum Abholen der Nachricht durch die Anwendung. Die INPROC-Zeit beinhaltet die INWAIT-Zeit, also die Zeit zwischen dem Anzeigen der Nachricht durch BCAM bei der Anwendung und dem Abholen der Nachricht durch die Anwendung.
- REACT:
  Zeit zwischen dem Sendeaufruf und dem unmittelbar vorangegangenen Empfangsaufruf einer Anwendung. Bei TP-Betrieb kann diese Zeit als Antwortzeit angesehen werden.
- OUTPROC:
  Zeit vom Sendeaufruf bis zur Übergabe des letzten Bytes der Nachricht an das Netz.

Der TCP-Transportservice arbeitet nicht nachrichten-orientiert, sondern stream-orientiert. Daher ist bei Transaktionen mit mehreren Antworten pro Eingabe die Ermittlung der Transaktionszeit durch BCAM nicht möglich. Ebenso wird die Denkzeit nicht erfasst.

Sofern die Eingabe-Nachrichtenlängen kurz sind (< 500 Bytes), kann die Anzahl empfangener TSDUs (Transport Service Data Units; Aufträge an BCAM) pro Sekunde als Maß für die Transaktionsrate interpretiert werden.

Die Messwerte INPROC, INWAIT, REACT und OUTPROC werden auch für Anwendungen erfasst, die mit dem Transportsystem BCAM über die Programmschnittstelle ICMX, IDCAM oder ITIAM zusammenarbeiten.

2.1.2 Batch-Verarbeitung

Die Einheit der IT-Arbeit bei Batch-Verarbeitung ist der **Auftrag** (Job).

Darstellung der Zeitdefinitionen

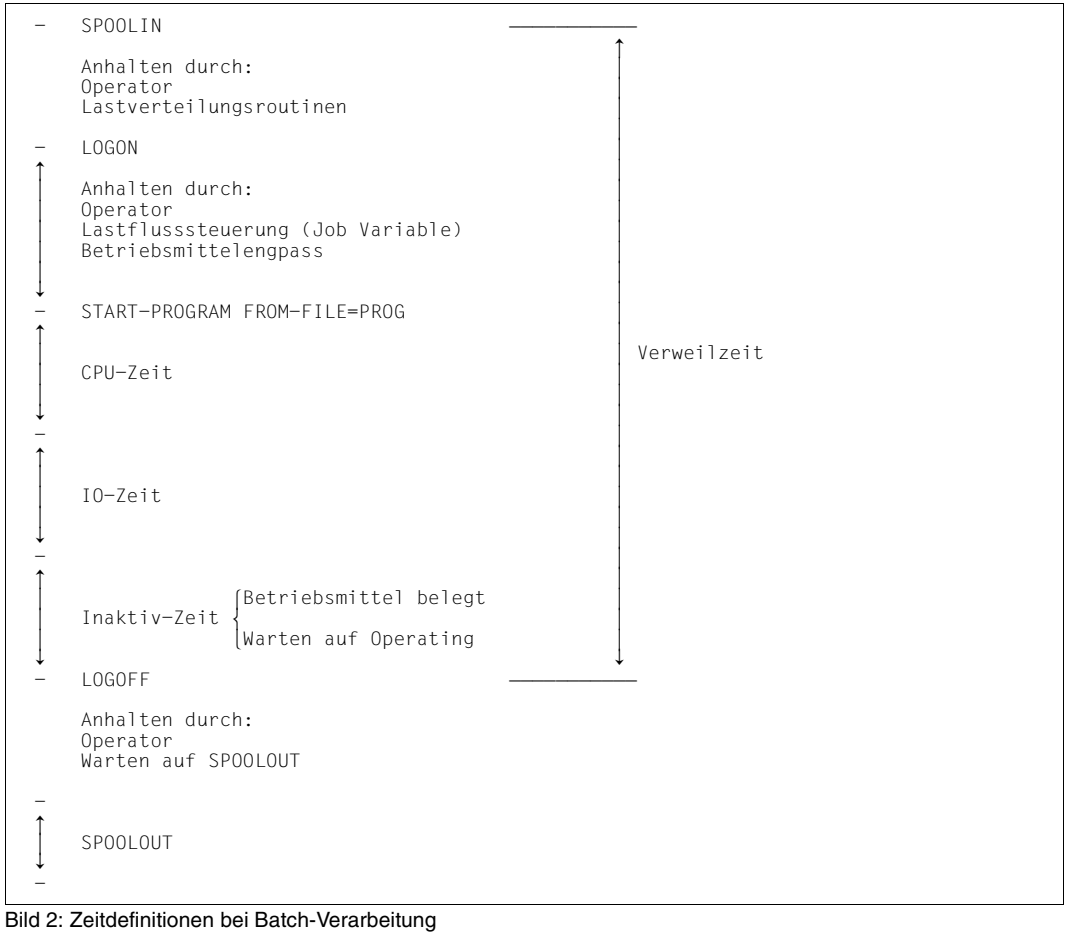

Bild 2: Zeitdefinitionen bei Batch-Verarbeitung

Kenngrößen bei Batch-Verarbeitung

- Durchsatzrate:
  Gesamtheit der erfolgreich ausgeführten Aufträge, bezogen auf die Zeiteinheit
- Verweilzeit:
  Zeit, die zur Verarbeitung eines Auftrages beansprucht wird

2.2 Formulieren einer Leistungserwartung

Zwischen der Transaktionszeit, der Transaktionsrate und der Anzahl Terminals besteht folgender grundlegender Zusammenhang:

$$(\text{DENKZEIT} + \text{TRANSAKTIONSZEIT}) \bullet \text{TRANSAKTIONSRATE} = \text{ANZAHL DER TERMINALS}$$

Unter dem Begriff Transaktionszeit fasst man die Reaktion des Systems auf sehr unterschiedliche Anforderungen zusammen. Es ist deshalb schwer zu entscheiden, ob eine Transaktionszeit angemessen ist. Wegen der Kosten für den Betrieb der Terminals und die Arbeitszeit des Bedieners empfiehlt sich folgende Sicht:

Während der Transaktionszeit kann das Terminal nicht genutzt werden. Es wartet auf den Server. Während der Denkzeit arbeiten Terminal und Anwender durch Lesen der Ausgabe bzw. Eintippen einer neuen Eingabe. Der Anteil der Denkzeiten an der gesamten Belegungszeit des Terminals ist der Wirkungsgrad für Terminals W. Sinkt dieser im Mittel aller Terminals unter 75%, so ist das ein Anzeichen für Leistungsprobleme.
Natürlich dürfen bei der Ermittlung der Denkzeiten „Verschnaufpausen“ nicht mitgemessen werden.

Es seien:

TH	(Think Time)	die Denkzeit
TT	(Transaction Time)	die Transaktionszeit
TR	(Transaction Rate)	die Transaktionsrate

Für den **Wirkungsgrad für Terminals** (**W)** gilt laut Definition:

$$W = \frac{TH}{TH + TT}$$

Die Anzahl der je Sekunde für eine Anwendung zu bewältigenden Transaktionen sei TR. Dann errechnet sich die für diese Anwendung benötigte Anzahl K von Terminals zu

$$K = (TH + TT) \bullet TR$$

$$K = \frac{1}{W} \bullet TH \bullet TR$$

Nimmt man einen Wirkungsgrad für Terminals von 0,75 an, so lautet die Formel:

$$K = 1{,}33 \bullet TH \bullet TR$$

Für verschiedene Wirkungsgrade gibt die folgende Tabelle die Werte für $\frac{1}{W}$ an.

W [%]	70	75	80	85	90	95
$\frac{1}{W}$	1,43	1,33	1,25	1,18	1,11	1,05

Die Formel $W = \frac{TH}{TH + TT}$
lässt erkennen, dass für lange Denkzeiten auch eine entsprechend lange Transaktionszeit (bzw. Antwortzeit bei nur **einer** Antwort pro Transaktion) akzeptiert werden kann, während sich die Transaktionszeiten bei kurzen Denkzeiten nachhaltig auf den Wirkungsgrad und damit auf die Anzahl der benötigten Terminals auswirken. Da in der Transaktionszeit die Netzlaufzeit enthalten ist, sollten die Terminals mit kurzen Denkzeiten und langen Ausgaben über schnelle Leitungen angeschlossen werden.

Neben dem Wirkungsgrad bestimmt die Auslastung U (Utilization) des Terminals die Anzahl der benötigten Terminals. Die Auslastung ist der Anteil an der Gesamtzeit, in der das Gerät entweder auf Antworten wartet (Transaktionszeit) oder mit der Vorbereitung einer neuen Eingabe tätig ist (Denkzeit). Verschnaufpausen z.B. senken die Auslastung, ohne dass das Gerät wirklich frei ist. Bei einer Datenerfassungsanwendung werden i.d.R. Belege von einem Stapel abgearbeitet. Man kann die Arbeitsplätze daher sehr hoch auslasten.
Eine Auslastung der Terminals von 90% ist möglich. Ein kleiner Verlust von 10% wird für Verschnaufpausen eingeplant. Für andere Anwendungen muss die Auslastung geringer angesetzt werden. Bei TP-Betrieb mit Publikumsverkehr möchte man dem Kunden lästige Wartezeiten ersparen. Diese entstehen, wenn gerade kein Terminal frei ist und der Kunde deshalb nicht sofort bedient werden kann. Ähnliche Verhältnisse findet man in der Programmentwicklung. In diesen Fällen sollte die Auslastung U der Terminals 60% nicht überschreiten.

Dann errechnet sich die **Anzahl der benötigten Terminals (K)** zu:

$$K = \frac{TH \bullet TR}{W \bullet U}$$

Beispiel

Es existieren 2 Anwendungen:

Die erste Anwendung ist eine Datenerfassung mit einer Denkzeit von 20 Sekunden und einer Transaktionszeit von 1 Sekunde. Im Mittel sind immer 90% aller Erfassungsplätze tätig. Pro Stunde müssen 7.200 Belege erfasst werden.

Die zweite Anwendung ist eine Platz-Buchungsanwendung mit Publikumsverkehr. Die Denkzeit beträgt 120 Sekunden, die Transaktionszeit 3 Sekunden. Damit keine spürbaren Wartezeiten für die buchungswilligen Kunden entstehen, werden die Terminals nur zu 60% genutzt. 360 Buchungen pro Stunde sind abzufertigen.

$W_1 = 95\%$ $U_1 = 90\%$ $TR_1 = 2/s$

$$(W_1 = \frac{TH}{TH + TT} = \frac{20s}{20s + 1s} = 0{,}95)$$

$W_2 = 97\%$ $U_2 = 60\%$ $TR_2 = 0{,}1/s$

$$K_1 = \frac{20 \bullet 2}{0{,}95 \bullet 0{,}90} = 47 \text{ Terminals}$$

$$K_2 = \frac{120 \bullet 0{,}1}{0{,}97 \bullet 0{,}60} = 21 \text{ Terminals}$$

Für die beiden Anwendungen werden zusammen 68 Terminals benötigt. Es ist sicherzustellen, dass die im Wirkungsgrad für Terminals enthaltenen Vorgaben für die Transaktionszeit vom Server eingehalten werden können.
Dies ist die zu formulierende Leistungserwartung.

Sie kann nur eingehalten werden, wenn der Server durch den Betriebsmittelbedarf der Anwendung nicht überbeansprucht wird und noch gewisse Leistungsreserven hat. Dabei spielt die Belastung derjenigen Betriebsmittel eine besonders große Rolle, die von der betrachteten Anwendung stark genutzt werden. Ist die Anwendung mit vielen Ein-/Ausgaben verbunden, dann ist für eine geringe Auslastung der Plattenlaufwerke zu sorgen. Zusätzliche freie Kapazitäten im Server bringen hier keine Verbesserung. Umgekehrt ist es bei rechenintensiven Anwendungen.
Paging wirkt sich in beiden Fällen negativ aus.

Jede Transaktionszeit hat eine natürliche untere Grenze. Diese wird erreicht, wenn das Terminal seine Transaktion auf einem sonst völlig lastfreien Server mit ebenso lastfreien Datenübertragungswegen abwickelt. Eine solche Nutzung eines IT-Systems ist natürlich unwirtschaftlich. Kommen andere Terminals und ggf. andere Anwendungen hinzu, dann wird der Ablauf durch gegenseitige Behinderung der Transaktionen untereinander gedehnt.

Der **Dehnfaktor (D)** wird wie folgt definiert:

$$D = \frac{\text{TT (aktuelle Belastung)}}{\text{TT (leerer Verarbeitungsrechner)}}$$

Die Dehnung ist der Preis für die wirtschaftliche Nutzung der Installation. Welche Dehnungen akzeptabel sind, hängt wieder von der Denkzeit und von der optimalen Transaktionszeit TT (leerer Server) ab. Bei kurzen Transaktionszeiten und langen Denkzeiten sind Dehnungen von 10 noch akzeptabel. Beträgt die optimale Transaktionszeit schon 3 Sekunden bei einer Denkzeit von nur 10 Sekunden, dann ist bereits die Dehnung 3 zu groß. Die **optimale Transaktionszeit** kann man entweder auf einem sonst betriebslosen Server messen oder nach folgender Formel abschätzen:

$$\text{TT (leerer Server)} = \text{CPU} + n \cdot \text{IO} + \text{NL}$$

mit:

CPU	für die Transaktion benötigte CPU-Zeit
IO	mittlere Zeit für einen Ein-/Ausgabe-Vorgang
n	Anzahl der für die Transaktion benötigten Ein-/Ausgaben (inkl. Paging)
NL	Netzlaufzeit für die Eingabe- **und** die Ausgabenachricht

Alle diese Werte sind durch Modifikationen an Hardware oder Software änderbar.
Bei den CPU- und IO-Zeiten sind meist mehrere Tasks zu berücksichtigen, beim Transaktionsbetrieb etwa UTM- und DBH-Tasks.

i Die von SM2 gemessene Dehnung berücksichtigt nicht die Netzlaufzeit. Es werden nur die Server-internen Daten verarbeitet.

Beispiel 1

Datenbankabfrage mit folgenden Werten:

CPU	0,1s
IO	0,004s
NL	0,1s
n	60

$$\text{TT (leerer Server)} = 0{,}1\text{s} + 60 \cdot 0{,}004\text{s} + 0{,}1\text{s} = 0{,}44\text{s}$$

Bei einem Dehnfaktor von 3 für Server und Netz ergibt sich ein $TT_{aktuell}$ von $3 \cdot 0{,}44 = 1{,}32 \approx 1{,}3$. Mit einer Denkzeit von 40 Sekunden berechnet sich ein Wirkungsgrad für Terminals von 97%:

$$W = \frac{TH}{TH + TT_{aktuell}} = \frac{40}{40 + 1{,}3} = 0{,}97$$

Beträgt die Denkzeit nur 20 s, sinkt der Wirkungsgrad für Terminals auf 94%.

In diesem Fall wäre zu prüfen, ob sich die IO-Zeiten verringern ließen, etwa durch weniger Ein-/Ausgaben oder durch eine schnellere Peripherie.

Beispiel 2

Blättern im Editor mit folgenden Werten:

```
CPU        0,01s
IO        0,004s
NL           1s
n             2
```

```
TT (leerer Server) = 0,01s + 2 • 0,004s + 1s ≈ 1,02s
```

Hier dominiert die Übertragungszeit des Ausgabebildschirms. Selbst bei einer Überlastung der Platten im Server (z.B. 0,025 s/IO) steigt die Transaktionszeit nur unmerklich auf 1,06 s. Bei einer Denkzeit von 3 Sekunden ergibt sich ein Wirkungsgrad für Terminals von 75%. Das ist unbefriedigend.

$$W = \frac{TH}{TH + TT} = \frac{3}{3 + 1{,}02} = 0{,}746$$

Eine Verdopplung der Leitungsgeschwindigkeit führt hier zu einer optimalen Transaktionszeit von 0,53 s. Nimmt man an, dass während der Übertragung der Nachrichten keine Dehnungen auftreten, dann bleibt diese Transaktionszeit auch bei realistischer Last erhalten. Der Wirkungsgrad für Terminals steigt auf 85%.

Die beiden Beispiele zeigen, dass die Ursachen für eine unzureichende Leistung vielfältig sein können. Überlastungen in der CPU, in der Peripherie und Kombinationen von Engpässen können auftreten. Der Abschnitt „Durchführung einer Engpass-Analyse“ auf Seite 303 und das Kapitel „Optimierungshinweise zur Erstellung von Anwender-Software“ auf Seite 337 geben Hilfen zum Aufdecken und Beseitigen solcher Probleme.

Die angeführten Formeln und Beispiele verdeutlichen, wie der Anwender seine Leistungserwartungen für den Online-Betrieb formulieren sollte. Das Ziel seines Handelns ist immer eine Kostenminimierung. Rechnet man die Einsparungen auf der einen Seite (z.B. für Personal und Terminals) gegen die Mehrkosten (z.B. für schnellere Leitungen, schnellere Rechner, schnellere Platten oder Programmänderungen) auf der anderen Seite auf, dann kommt man immer zu einer fundierten Leistungserwartung. Unter Berücksichtigung der Preisbewegungen für die Hardware sollten die gefundenen Entscheidungen in gewissen Zeitabständen überprüft werden.

Natürlich dürfen subjektive Gesichtspunkte nicht ganz vernachlässigt werden, etwa die psychologisch schädliche Wirkung gelegentlicher langer Transaktionszeiten. Die darauf aufgebauten Leistungserwartungen führen jedoch auf Irrwege. Die Beseitigung einzelner langer Transaktionszeiten ist meist sehr aufwändig und führt i.d.R. nicht zu generellen Einsparungen.

3 Leistungsverhalten der Server

Eine vergleichende Übersicht über die Leistungsdaten und Richtwerte der verschiedenen Servermodelle finden Sie im Abschnitt „Richtwerte für die BS2000/OSD-Server“ auf Seite 353.

3.1 CPU

3.1.1 Relativer Performance Faktor (RPF)

In der BS2000-Welt wird die Leistung eines Servers mit der Kennzahl RPF (Relativer Performance Faktor) ausgedrückt. Der RPF-Wert gibt die Leistungsfähigkeit der CPUs unter realistischer Last an.

Zur RPF-Bestimmung werden Messungen mit zwei Benchmark-Lasten durchgeführt. Diese bestehen aus einer OLTP-Last (TP-Benchmark mit UTM- und SESAM/SQL-Applikationen) und einer Batch-Last (SKBB-Benchmark mit COBOL-Programmen).

Es wird der Leistungswert für den Batch-Betrieb (RPF_{SKBB} über das Leistungsmaß „Jobs pro CPU-Sekunde“) und den TP-Betrieb (RPF_{TP} über das Leistungsmaß „Transaktionen pro CPU-Sekunde“) ermittelt.

Das Ergebnis des TP-Betriebs geht nun mit 75%, das Ergebnis des Batch-Betriebs mit 25% in den Gesamt-RPF-Wert ein.

Beispiele für die Ermittlung des RPF-Wertes (die ermittelten Messwerte werden zu den Messwerten der Referenzmaschine C40-F (RPF=1) in Bezug gesetzt):

Modell	**Anzahl CPUs**	**RPF_{SKBB}** (RPF-Wert mit SKBB-Benchmark)	**RPF_{TP}** (RPF-Wert mit TP-Benchmark)	**RPF_{gesamt}** (gewichteter Mittelwert aus RPF_{SKBB} und RPF_{TP})
C40-F	1	1	1	1
S165-10D	1	534	289	350
S200-40	4	2.285	1.265	1.520

Tabelle 1: Beispiele zum RPF/Wert (Teil 1 von 2)

Modell	Anzahl CPUs	RPF_{SKBB} (RPF-Wert mit SKBB-Benchmark)	RPF_{TP} (RPF-Wert mit TP-Benchmark)	RPF_{gesamt} (gewichteter Mittelwert aus RPF_{SKBB} und RPF_{TP})
SX160-10A	1	63	35	42
SX160-60C	6	780	450	530
SQ100-10D	1	85	53	60
SQ100-40D	4	269	183	200

Tabelle 1: Beispiele zum RPF/Wert (Teil 2 von 2)

Es ist generell problematisch, das Leistungsverhalten eines Servers mit einer einzigen Zahl auszudrücken. Wie aus vorangehender Tabelle zu ersehen ist, hängt die Leistung in gewissen Grenzen vom Anwendungsprofil ab.

Auf SX- und SQ-Servern ist wegen der besonderen Architektur dieser Server und des lastabhängigen Wirkungsgrades der CISC-Firmware (siehe Seite 31 und Seite 33) eine stärkere Abhängigkeit vom Anwendungsprofil und damit eine größere Bandbreite der Leistung zu erwarten.

3.1.2 Multiprozessor-Systeme

Multiprozessor-Systeme bestehen aus 2 bis 15 Verarbeitungsprozessoren und 1 bis 4 I/O-Prozessoren. Die Vorteile liegen in der Erhöhung der Verfügbarkeit sowie einer entsprechenden Leistungssteigerung.

Voraussetzung für eine performante Nutzung von Multiprozessor-Systemen ist die Multiprozessor-Fähigkeit der Anwendung: Dazu muss die Anwendung in der Lage sein, die Anforderungen nicht nur parallel abzuarbeiten, sondern diese auch ohne wesentliche gegenseitige Beeinträchtigung abzuwickeln.

Erhöhte Verfügbarkeit

Bei geeigneter, redundanter Auslegung der Hardware erfolgt bei Ausfall einer Hardware-Komponente die automatische Rekonfiguration durch das System ohne Unterbrechung des laufenden Betriebs.

Leistungssteigerung

Im Multiprozessor-Modus können unter der Steuerung **eines** BS2000-Betriebssystems mehrere Tasks parallel (je nach Anzahl der CPUs) bedient werden. Um dieses mehrfache Leistungsangebot zu nutzen, muss also dafür gesorgt werden, dass stets genügend Tasks zur parallelen Verarbeitung vorhanden sind.

Es ist zu beachten, dass jeder Task nur die Leistung **einer** CPU zur Verfügung steht. Daraus ergibt sich, dass das Antwortzeitverhalten nur bedingt verbessert werden kann (durch die weiteren CPUs kann lediglich die Wartezeit auf CPU-Zuteilung verkürzt werden). Analoges gilt für Batch-Anwendungen: Nur der Teil der Laufzeit einer Batch-Anwendung kann deutlich reduziert werden, der durch Parallelisierung des reinen Rechenbedarfs erreicht wird.

Zur Höhe der verbrauchten CPU-Zeit einer Task ist anzumerken, dass diese (bei gleicher Arbeit) i.d.R. etwas höher ist, als auf dem entsprechenden Monoprozessor.
Je größer die Anzahl CPUs ist, desto stärker steigt der Aufwand für die Hauptspeicher-Synchronisation, verbunden mit einer Abnahme der Cache-Hit-Rate.

Die CPU-Zeit wird sich in folgendem Rahmen erhöhen:

– bei 2 CPUs um 5 bis 10%
– bei 4 CPUs um 10 bis 15%
– bei 6 CPUs um 15 bis 20%
– bei 8 CPUs um 20 bis 30%
– bei 10 CPUs um 25 bis 35%
– bei 12 CPUs um 30 bis 40%
– bei 15 CPUs um 35 bis 45%

Unter der Voraussetzung der Aufteilung der Last auf parallel laufende, möglichst voneinander unabhängige Tasks kann die Transaktionsrate wesentlich gesteigert werden.
Gegenüber einem Monoprozessor können auf S-Servern folgende Durchsatzsteigerungen erreicht werden:

– bei 2 CPUs um den Faktor 1,7 bis 1,9
– bei 4 CPUs um den Faktor 3,3 bis 3,6
– bei 6 CPUs um den Faktor 4,6 bis 5,2
– bei 8 CPUs um den Faktor 5,8 bis 6,6
– bei 10 CPUs um den Faktor 6,8 bis 7,8
– bei 12 CPUs um den Faktor 7,8 bis 8,8
– bei 15 CPUs um den Faktor 8,8 bis 9,9

Um bei erhöhter Task-Anzahl die gestiegenen Betriebsmittelanforderungen zu befriedigen, ist der Ausbau des Hauptspeichers und die Erhöhung der Anzahl der Plattenlaufwerke unbedingt erforderlich.

Empfohlene maximale CPU-Auslastung

Bei antwortzeitkritischen Anwendungen sollte bei Monoprozessoren eine CPU-Auslastung von 70% für die Hauptanwendung nicht überschritten werden, weil mit steigender Auslastung die Wartezeit in der Warteschlange vor der CPU überproportional ansteigt (siehe auch Abschnitt „Untersuchen eines systemorientierten Leistungsproblems“ auf Seite 311).

Bei Multiprozessor-Systemen ist die Wahrscheinlichkeit, eine freie CPU zu finden, umso größer, je mehr CPUs zur Verfügung stehen. Deshalb können auch höhere Auslastungen toleriert werden. Bei antwortzeitkritischen Anwendungen sollten folgende CPU-Auslastungen für die Hauptanwendung nicht überschritten werden:

- 75% bei 2 CPUs
- 80% bei 4 CPUs
- 85% bei 6 CPUs
- 90% ab 8 CPUs

3.1.3 CPU-Leistung von SX-Servern

Grundlegende Informationen über SX-Server finden Sie in den Handbüchern zu den Business-Servern der SX-Serie, speziell im Handbuch „Konzepte und Funktionen“ [3]. Die folgenden Abschnitte beschäftigen sich mit den Komponenten der SX-Server, die Auswirkungen auf die CPU-Leistung der SX-Server haben.

CPUs

Die in der BS2000-Partition verfügbaren CPUs werden logisch aufgeteilt in CPUs für Anwendungen unter BS2000/OSD (BS2000-CPUs) und CPUs, die X2000 dem BS2000/OSD bereitstellt (I/O-Prozessoren).

Bis zu sechs CPUs können als BS2000-CPUs genutzt werden, mindestens eine CPU muss als I/O-Prozessor zur Verfügung stehen. Für Verschlüsselungsaufgaben können bis zu zwei CPUs bereitgestellt werden.

Eine spezielle X2000-Firmware-Schicht unterstützt den Ablauf des Betriebssystems BS2000/OSD und den kompatiblen Ablauf von /390-Anwendungen auf den BS2000-CPUs, sowie die Durchführung von Ein-/Ausgaben auf dem I/O-Prozessor.

CISC-Firmware, JIT390

Die CISC-Firmware (CISCFW) ist die Firmware-Komponente zur Abbildung von nicht privilegiertem /390-Code auf SPARC64-Code. Sie ergänzt den SPARC64-Modus und ermöglicht es, existierenden /390-Code objektkompatibel (im /390-Modus, synonym: Kompatibilitätsmodus) auf SPARC64-Hardware ablaufen zu lassen. Die CISC-Firmware enthält die Komponente JIT390, einen Just-In-Time-/390-Code-Übersetzer, der /390-Code zur Ablaufzeit in SPARC64-Code umsetzt. Ein Code-Block wird erst bei seiner Ausführung übersetzt und in einem task-lokalen JIT-Puffer vorgehalten. Kommt der Code-Block erneut zur Ausführung, so wird der bereits übersetzte und optimierte Code aus dem JIT-Puffer direkt ausgeführt. Die Wiederverwendung von vorgefertigten und optimierten Code-Teilen ist im Vergleich zur erneuten Interpretation deutlich schneller bei gleichzeitig geringerer Prozessorbelastung. Zur weiteren Optimierung wird der JIT-Puffer als residenter Speicher angelegt.

Bestehende (unprivilegierte) Kundenanwendungen laufen unverändert im /390-Code objektkompatibel mittels der CISC-Firmware ab. Dies gilt sowohl für Anwendungen, die mit ASSEMBH erzeugt wurden, als auch für Programme, die mit den BS2000-Compilern für höhere Programmiersprachen erzeugt wurden. SX-Server unterstützen auch ESA-Datenräume in Kundenanwendungen. System Exits und Objekte, die im speziellen RISC-Objektformat für SR2000 vorliegen, müssen neu übersetzt werden.

Die effektive Leistung eines SX-Servers ist davon abhängig, in welchem Ausmaß innerhalb einer /390-Anwendung Systemaufrufe vorkommen und wie stark die /390-Anwendung von der Effizienz der CISC-Firmware profitiert. Systemaufrufe werden im Funktionszustand

TPR bzw. SIH des Servers, also im SPARC64-Modus, abgearbeitet. Die Anwendungen laufen im Funktionszustand TU, also im /390-Modus, ab.

Der Wirkungsgrad der CISC-Firmware hängt also von der Nutzung des JIT-Puffers durch die jeweilige Last ab: einerseits von der Wiederholungsrate bestimmter /390-Code-Teile (geringerer CPU-Bedarf) und andererseits von der Größe der in SPARC64-Code übersetzten Programmteile einer /390-Anwendung
(höhere Hauptspeicher- und Hauptspeicher-Cache-Belastung).

CPU-Leistung

Die für die Leistungsmessung verwendeten Benchmarks laufen auf S-Servern im Mittel zu 40% im Funktionszustand TU und zu 60% in TPR/SIH ab (die Werte sind auf 100% CPU-Auslastung normiert). Durch die unterschiedliche Leistungsaufnahme im /390- bzw. SPARC64-Modus und durch den unterschiedlichen Wirkungsgrad der CISC-Firmware laufen diese Benchmarks auf SX-Servern zu 60% im Funktionszustand TU und zu 40% in TPR/SIH. Der für die SX-Server angegebene RPF-Wert (siehe „Richtwerte für SX-Server“ auf Seite 358) wird unter diesen Randbedingungen, die für die meisten BS2000-Einsatzfälle typisch sind, erreicht.
Für Anwendungen, die im /390-Modus laufen, ist also ein hoher Anteil im Funktionszustand TU normal, normiert auf 100% Auslastung. Wird ein höherer (normierter) TU-Anteil ausgewiesen, so liegt die Leistung eines SX-Servers **unter** dem oben genannten RPF-Wert (Nominalwert). Bei einem kleineren (normierten) TU-Anteil liegt die Leistung **über** dem Nominalwert.

Im Extremfall „sehr niedriger TU-Anteil“ kann ein SX-Server bis zum 1,6-fachen des Nominalwertes leisten; im anderen Extremfall „sehr hoher TU-Anteil im /390-Modus“ kann die Leistung des SX-Servers auf 60% des Nominalwertes absinken.

Auf SX-Servern werden im Vergleich zu S-Servern bei technisch-wissenschaftlichen Anwendungen (mit großem Anteil an Floating-Point-Befehlen) geringere Leistungen erzielt; im Einzelfall kann sich eine Abweichung von mehr als 20% gegenüber der nominalen Leistung ergeben. Geringere Leistungen können sich auch in folgenden Fällen ergeben:
– sehr häufiges Auftreten von Ausrichtungsverstößen
  (z.B. Speicheroperand nicht auf Wortgrenze ausgerichtet beim Assemblerbefehl A)
– EX-Befehle
– selbstmodifizierender Code
– Mischung von Code und Daten auf derselben Speicherseite

Produkte, deren /390-Code auf SPARC64-Code portiert wurde (wie z.B. SESAM/SQL-Server), laufen auf SX-Servern deutlich performanter ab, und zwar um bis zu 30%.

Eine weitere Erhöhung der Leistung eines SX-Servers ergibt sich für Produkte, die in C/C++ geschrieben sind und mit einem speziell auf die SPARC64-Hardware optimierten Compiler produziert wurden. Dabei ist eine Verdoppelung der RPF-Leistung möglich, mit ORACLE liegen die Verbesserungen z.B. bei über 50%.

3.1.4 CPU-Leistung von SQ-Servern

Grundlegende Informationen über SQ-Server finden Sie im Handbuch „Bedienen und Verwalten“ [5]. Die folgenden Abschnitte beschäftigen sich mit den Komponenten der SQ-Server, die Auswirkungen auf die CPU-Leistung der SQ-Server haben.

CPUs

Die verfügbaren CPUs werden logisch aufgeteilt in CPUs für Anwendungen unter BS2000/OSD (BS2000-CPUs) und CPUs, auf denen BS2000-I/Os und Administrationsaufgaben für den SQ-Server durch X2000 abgewickelt werden (I/O-Prozessoren).

Abhängig vom SQ100-Modell können bis zu vier CPUs als BS2000-CPUs genutzt werden. Wenigstens eine CPU steht zusätzlich als I/O-Prozessor zur Verfügung.
Daneben steht eine zusätzliche CPU als „Cold Spare“-CPU zur Verfügung. Im Normalbetrieb wird diese CPU von X2000 als weiterer I/O-Prozessor genutzt.

Eine spezielle X2000-Firmware-Schicht unterstützt den Ablauf des Betriebssystems BS2000/OSD und den kompatiblen Ablauf von /390-Anwendungen auf den BS2000-CPUs, sowie die Durchführung von Ein-/Ausgaben auf den I/O-Prozessoren.

CISC-Firmware

Die CISC-Firmware (CISCFW) ist die Firmware-Komponente zur Abbildung von nicht privilegiertem /390-Code auf x86-Code. Sie ergänzt den x86-Modus und ermöglicht es, existierenden /390-Code objektkompatibel (im /390-Modus, synonym: Kompatibilitätsmodus) auf x86-Hardware ablaufen zu lassen.

Dies gilt sowohl für Anwendungen, die mit ASSEMBH erzeugt wurden, als auch für Programme, die mit den BS2000-Compilern für höhere Programmiersprachen erzeugt wurden. SQ-Server unterstützen auch ESA-Datenräume in Kundenanwendungen. System Exits und Objekte, die im speziellen RISC-Objektformat für SR2000 oder SPARC64-Objektformat für SX-Server vorliegen, müssen neu übersetzt werden.

Auf dem Business Server SQ100 stehen keine Anwendungsbeschleuniger, wie der Just-in-Time Translator (JIT390) in der CISC-Firmware der SX-Server, zur Verfügung.
Gleiches gilt für die Datenbank-Beschleuniger, die die Datenbank-Server-Tasks von SESAM/SQL und von Oracle auf SX-Servern über den nominellen RPF-Wert hinaus beschleunigt haben.
Die nominalen RPF-Werte (siehe „Richtwerte für SQ-Server“ auf Seite 361) lassen nicht immer zuverlässige Rückschlüsse auf Laufzeiten, Transaktionsraten oder CPU-Zeitverbrauch zu. Diese Werte können anwendungsbedingt nach oben oder nach unten abweichen.
Siehe auch den Abschnitt „Migration von S-Servern auf SQ-Server“ auf Seite 53.

CPU-Leistung

Die für den Business Server SQ100 gemessenen RPF-Werte gelten für Anwendungen mit einem TU-Anteil von 40-60%. Bei Anwendungen mit einem TU-Anteil außerhalb dieses Bereichs kann die Leistung der Anwendung von den nominalen RPF-Werten abweichen.

3.2 CPU-naher Speicher

3.2.1 Hauptspeicher

Insbesondere für TP-Betrieb ist eine zu hohe Paging-Rate kritisch (siehe die Server-spezifische maximal empfohlene Anzahl von Paging-Ein-/Ausgaben im Abschnitt „Richtwerte für die BS2000/OSD-Server“ auf Seite 353). Eine zu hohe Paging-Rate führt immer zu unbefriedigenden Antwortzeiten. Wenn die kritische Anzahl von Paging-Ein-/Ausgaben immer wieder erreicht oder sogar überschritten wird, dann ist eine Hochrüstung des Hauptspeicherausbaues nötig.

Im VM2000-Betrieb sollte vor einer allgemeinen Hochrüstung des Hauptspeicherausbaues der Hauptspeicher optimal auf die Gastsysteme aufgeteilt werden.

Überwachen der Hauptspeichernutzung

Die Auslastung des Hauptspeichers sollte von der Systembetreuung kontinuierlich mit SM2 beobachtet werden, um einen drohenden Hauptspeicherengpass frühzeitig zu erkennen.

Für die Berechnung und Bewertung der Speicherauslastung sind folgende Kennzahlen von Bedeutung (siehe auch „Seitenverwaltungs-Algorithmus (System Working Set-Verfahren, SYS-WS)“ auf Seite 277):

- NPP (Number of Pageable Pages): Anzahl der seitenwechselbaren Seiten (entspricht der Größe des zur Verfügung stehenden Hauptspeichers minus der Anzahl residenter Seiten)
- SWS (System Working Set): Anzahl der global genutzten Seiten (entspricht NPP minus der Anzahl der frei nutzbaren Seiten im so genannten Freepool)

i Das Ergebnis der hier empfohlenen Bewertungsmethode ist umso genauer, je mehr man sich einem Speicherengpass bzw. der kritischen Paging-Rate nähert.

Der Nutzungsgrad des Hauptspeichers (in Prozent) ergibt sich aus der Formel:

$$N = \frac{SWS \bullet 100}{NPP}$$

Messwerte für N bis 75% gelten als unkritisch.
Bei Werten für N größer als 90% sollte an eine Hochrüstung des Hauptspeicherausbaues gedacht werden. Dies gilt insbesondere, wenn die neue Version eines Softwareprodukts eingeführt werden soll und diese Software von mehreren Tasks verwendet wird.

3.2.2 Globalspeicher (GS)

Der Globalspeicher (Global Storage, GS) ist ein flüchtiger Halbleiterspeicher für S-Server. Er besteht aus maximal 2 unabhängigen Hardware-Einheiten (GS-Units) und kann durch den Einsatz einer Batterie zu einem nichtflüchtigen Speichermedium gemacht werden.

Der GS kann von der Systembetreuung in Abschnitte („Partitions“) aufgeteilt werden, die den GS-Nutzern zur Verfügung stehen (siehe Handbuch „Einführung in die Systembetreuung“ [11]).

Explizit kann der GS im Rahmen des HIPERFILE-Konzepts eingesetzt werden:

- durch DAB für ADM-PFA- und PFA-Cache-Bereiche als nichtflüchtiger Read-Write-Cache (Partition DAB)
- zur Emulation von schnellen Platten (GSVOL, Partition GSV)
- sowie als Koppelmedium im HIPLEX-Verbund (Partition NSM)

Nutzung für das Caching von Dateien

Der GS mit Batterie ermöglicht durch seine Nichtflüchtigkeit ein ausfallsicheres, schnelles Schreiben. BS2000/OSD führt neben den Nutzdaten auch die Verwaltungsdaten im GS, so dass nach einem Systemabbruch die Zuordnung der Daten wiederhergestellt werden kann. Durch diese Eigenschaften ist der GS für das gesamte Spektrum der Dateiverarbeitung als Cache einsetzbar (Read-, Write-, Read-Write-Cache, siehe Abschnitt „Arbeiten mit HIPERFILEs“ auf Seite 195) und ermöglicht bei entsprechender Hit-Rate eine deutliche Verkürzung der Ein-/Ausgabezeiten bzw. Erhöhung des Ein-/Ausgabe-Durchsatzes.

Schreibaufträge werden bei einem Read-Write-Cache (bzw. Write-Cache) immer in den Cache eingetragen, d.h. die Hit-Rate für Schreiben beträgt immer 100 %.
Die Ein-/Ausgabezeit (Zugriffs- und Transferzeit der Hardware + Verwaltungszeit für die Software) beträgt für 4 KB beim Hit ca. 0,1 Millisekunden (an S140/S170). Gegenüber einem Cache bei Plattenspeichersystemen bedeutet dies eine Beschleunigung der Ein-/Ausgabe ca. um das 8-fache, falls das Plattenspeichersystem über Typ S-Kanal angeschlossen ist, bzw. ca. um das 4-fache bei einem Typ FC-Kanalanschluss. Da das Caching im GS unter der Steuerung von BS2000/OSD erfolgt, tritt allerdings ein entsprechender CPU-Zeitbedarf auf (siehe Abschnitt „ADM-PFA-Caching“ auf Seite 199).

Nutzung als Plattenemulation

Der GS ermöglicht durch seine Nichtflüchtigkeit auch, in diesem Speichermedium Platten zu emulieren und damit extrem schnelle Plattenspeicher, sogenannte GS-Volumes, zur Verfügung zu stellen (siehe Abschnitt „Platten-Emulation (GS-Volumes) im Globalspeicher“ auf Seite 207).

GS-Volumes bieten eine gleich hohe Ein-/Ausgabe-Performance wie GS-Caching mit DAB, ohne dass Randbedingungen wie gute Lokalität der Anwendungszugriffe (hohe Hit-Rate) erfüllt sein müssen. Somit kommt die oben erwähnte Verkürzung der Ein-/Ausgabezeit um den Faktor 8 bzw. 4 gegenüber einem Plattenspeichersystem bei GS-Volumes grundsätzlich zum Tragen, jede Ein-/Ausgabe auf ein GS-Volume profitiert davon. Außerdem tritt **keine** Erhöhung des CPU-Zeitbedarfs für Ein-/Ausgaben auf GS-Volumes gegenüber normalen Platten-Ein-/Ausgaben auf.

3.2.3 Hauptspeicher auf SX-Servern

Der Hauptspeicher wird zwischen BS2000/OSD und X2000 (I/O-Prozessor) aufgeteilt. Eine Empfehlung für den Hauptspeicherausbau der SX-Server, sowie die Aufteilung in BS2000/OSD- und X2000-Hauptspeicher, die für die meisten Anwendungsfälle zutreffend sein sollte, finden Sie im Abschnitt „Richtwerte für SX-Server“ auf Seite 358.
Die angebotenen Standardmodelle der SX-Server werden mit diesem empfohlenen Speicherausbau ausgeliefert.

In den meisten Fällen müssen die Standardeinstellungen für die Hauptspeicherverwaltung nicht geändert werden. Eine Vergrößerung des Hauptspeichers ist in folgenden Fällen in Betracht zu ziehen:

- Vergrößerung des X2000-Hauptspeichers

  Bei einer Vergrößerung des Gesamt-Hauptspeichers (z.B. für BS2000/OSD) ist auch ein Anteil für X2000 vorzusehen. Als Richtwert gilt ein Anteil des X2000-Hauptspeichers von ca. 20% des zusätzlichen Speichers. Richtwert: der Anteil des X2000-Hauptspeichers am Gesamt-Hauptspeicher beträgt 20%.

  Bei großen Konfigurationen (etwa ab 512 LUNs und 32 ETERNUS CS (CentricStor) Geräten) muss für X2000 ein größerer Hauptspeicherausbau vorgesehen werden als im Abschnitt „Richtwerte für SX-Server“ auf Seite 358 angegeben. Richtwert: der Anteil des X2000-Hauptspeichers am Gesamt-Hauptspeicher beträgt 25%.

- Vergrößerung des Hauptspeichers von BS2000/OSD

  Sollen mehr als die empfohlene maximale Anzahl virtueller Maschinen betrieben werden, muss der Hauptspeicher für BS2000/OSD vergrößert werden. (Maximal 15 virtuelle Maschinen sind freigegeben.)

  Ebenso kann beim Einsatz extrem vieler oder extrem großer Tasks ein größerer Hauptspeicherausbau notwendig werden. Denn hierbei erhöht sich insbesondere der Bedarf an JIT-Puffer, für den standardmäßig 40% des Hauptspeichers von BS2000/OSD reserviert werden. Weitere Informationen dazu finden Sie im Abschnitt „Puffergröße der CISC-Firmware“ auf Seite 374.

- Änderung des Hauptspeichers einer VM unter VM2000

  Folgende Beschränkung gilt **nicht** mehr für VM2000-Gastsysteme ab BS2000/OSD V7.0 auf SX-Servern ab SX160 / SX100-D:

  Falls bei Einsatz von VM2000 einer VM im laufenden Betrieb Speicher entzogen werden soll, muss dies durch eine entsprechende Einstellung der `MIN-MEMORY-SIZE` vorbereitet worden sein. Dabei ist zu beachten, dass für den JIT-Puffer genügend Speicher bereitgestellt wird.

  Die folgende Regel muss deshalb in jedem Fall eingehalten werden:
  `MIN-MEMORY-SIZE > 1/2 * MEMORY-SIZE.`

Dabei werden 40% residenter Speicher für den JIT-Puffer und etwa 10% residenter Speicher für das Betriebssystem berücksichtigt. Falls weiterer residenter Speicher verwendet wird (z.B. durch DAB), ist auch dieser zu addieren. Weitere Informationen dazu finden Sie im Kapitel „Performance-Aspekte bei VM2000-Betrieb“ auf Seite 139 und im Abschnitt „Puffergröße der CISC-Firmware“ auf Seite 374.

3.2.4 Hauptspeicher auf SQ-Servern

Der Hauptspeicher wird zwischen BS2000/OSD und der Domäne 0 (Dom0) bzw. X2000 (I/O-Prozessoren) aufgeteilt.
Eine Empfehlung für den Hauptspeicherausbau der SQ-Server, sowie die Aufteilung in BS2000/OSD- und Dom0/X2000-Hauptspeicher, die für die meisten Anwendungsfälle geeignet ist, finden Sie im Abschnitt „Richtwerte für SQ-Server“ auf Seite 361.
Die angebotenen Standardmodelle der SQ-Server werden mit diesem empfohlenen Speicherausbau ausgeliefert.

In den meisten Fällen müssen die Standardeinstellungen für die Hauptspeicherverwaltung nicht geändert werden. Eine Vergrößerung des Hauptspeichers ist in folgenden Fällen in Betracht zu ziehen:

- Vergrößerung des Dom0/X2000-Hauptspeichers

  Bei einer Vergrößerung des Gesamt-Hauptspeichers (z.B. für BS2000/OSD) ist auch ein Anteil für Dom0/X2000 vorzusehen. Als Richtwert gilt ein Anteil des Dom0/X2000-Hauptspeichers von ca. 30% des zusätzlichen Speichers. Richtwert: der Anteil des Dom0/X2000-Hauptspeichers am Gesamt-Hauptspeicher beträgt 30%.

  Bei großen Konfigurationen (etwa ab 512 LUNs und 32 ETERNUS CS (CentricStor) Geräten) muss für Dom0/X2000 ein größerer als der Standard-Hauptspeicherausbau vorgesehen werden. Richtwert: der Anteil des Dom0/X2000-Hauptspeichers am Gesamt-Hauptspeicher beträgt 35%.

- Vergrößerung des Hauptspeichers von BS2000/OSD

  Der Einsatz extrem vieler oder extrem großer Tasks kann einen größerer Hauptspeicherausbau notwendig machen.

3.3 Ein-/Ausgabe

3.3.1 Ein-/Ausgabe auf S-Servern

An den S-Servern können Geräte über Kanalanschlusstechnik (Kanalperipherie) betrieben werden. Fibre Channel-Peripherie (FC-Peripherie) kann über den Kanal Typ FC angeschlossen werden.

3.3.1.1 Kanal Typ S

Die Datenübertragung erfolgt seriell über einen Lichtwellenleiter mit einer maximalen Datenrate von 17 Mbyte/s.

Wesentliche Leistungsmerkmale des Kanals Typ S sind:

- Halbduplex-Betrieb
- Maximal **eine** Ein-/Ausgabe-Operation kann zu einer Zeit durchgeführt werden
- Effektive Datenrate bei großen Ein-/Ausgabe-Blöcken: bis zu 15 Mbyte/s
- Direkter Anschluss einer Steuerung (CU) bis zu einer Entfernung von 3 km möglich
- Maximale Entfernung eines S-Connection-Directors (SCD 3950-3, Port Typ S1): 3 km; Der SCD ist ein optischer Matrixschalter mit maximal 248 Anschluss-Ports Typ S1 (Multi Mode Fibre: 3 km) oder Typ S2 (Single Mode Fibre: 20 km) zum Anschluss eines weiteren SCDs in Serie.
  (SCDs werden ab BS2000/OSD V8.0 nicht mehr bedient.)
- Absinken der maximalen Datenrate bei Übertragungen über Entfernungen > 9 km (bei 23 km liegt die maximale Datenrate etwa bei 9 Mbyte/s)

Die maximale Datenrate gilt nur für die Übertragung des Ein-/Ausgabe-Blocks. Durch das pro Ein-/Ausgabe-Block abzuwickelnde Protokoll zwischen Kanal und Steuerung (= Channel-Director beim Plattenspeichersystem Symmetrix) ergibt sich eine effektive Datenrate, die umso geringer ist, je kleiner die verwendeten Blockgrößen sind.

Zusammen mit einem Symmetrix-System 8530, reiner Lese-Last und 100 % Read-Hit-Rate schafft ein Kanal Typ S abhängig von der Blockgröße und vom Datenformat maximal folgende Ein-/Ausgabe- bzw. Durchsatzraten:

Blockgröße	Datenformat K		Datenformat NK4	
	Ein-/Ausgaben pro Sekunde	Mbyte pro Sekunde	Ein-/Ausgaben pro Sekunde	Mbyte pro Sekunde
2 KB	1500	3,1	-----	------
4 KB	1100	4,5	1300	5,3
8 KB	700	5,7	950	7,8
16 KB	420	6,9	600	9,8
32 KB	240	7,9	360	11,8

3.3.1.2 Kanal Typ FC

Die Datenübertragung erfolgt seriell über einen Lichtwellenleiter mit einer maximalen Datenrate von 100 Mbyte/s.

Wesentliche Leistungsmerkmale des Kanals Typ FC sind:

- Vollduplex Betrieb
- Maximal **acht** Ein-/Ausgabe-Operationen (von verschiedenen Steuerungen) können zu einer Zeit durchgeführt werden
- Effektive Datenrate bei großen Ein-/Ausgabe-Blöcken: mehr als 90 Mbyte/s möglich
- Anschluss von FC-Geräten nur über FC-Switch möglich
- Maximale Entfernung eines FC-Switches: 550 m
- Absinken der max. Datenrate erst bei Übertragungen über Entfernungen >100 km
- Deutliche Reduktion der Ein-/Ausgabezeit gegenüber dem Kanal Typ S in Abhängigkeit der Blockgröße. Pro Ein-/Ausgabe verringert sich die Protokollzeit (= Zeit für die Kommunikation zwischen Kanal und Channel-Director des Symmetrix-Systems) um 0,2 ms, sowie die Datentransferzeit um 0,1 bis 0,2 ms je 2 KB-Block.
- Es werden nur Platten mit FBA-Formatierung unterstützt (siehe Abschnitt „Eigenschaften von Plattenspeichersystemen“ auf Seite 57).

Folgende Geräte werden über Kanal Typ FC unterstützt:

- Symmetrix-Plattenspeichersysteme: 8000, DMX, V-Max
- ETERNUS CS (CentricStor):
  VTA (Virtual Tape Appliance), SBU (Smart Backup Unit), VTC (Virtual Tape Controller)
- MBK-Geräte LTO-x in den MBK-Archivsystemen Scalar 10K, i500 und i2000
- High-Speed Net Connect HNC-IV 91853

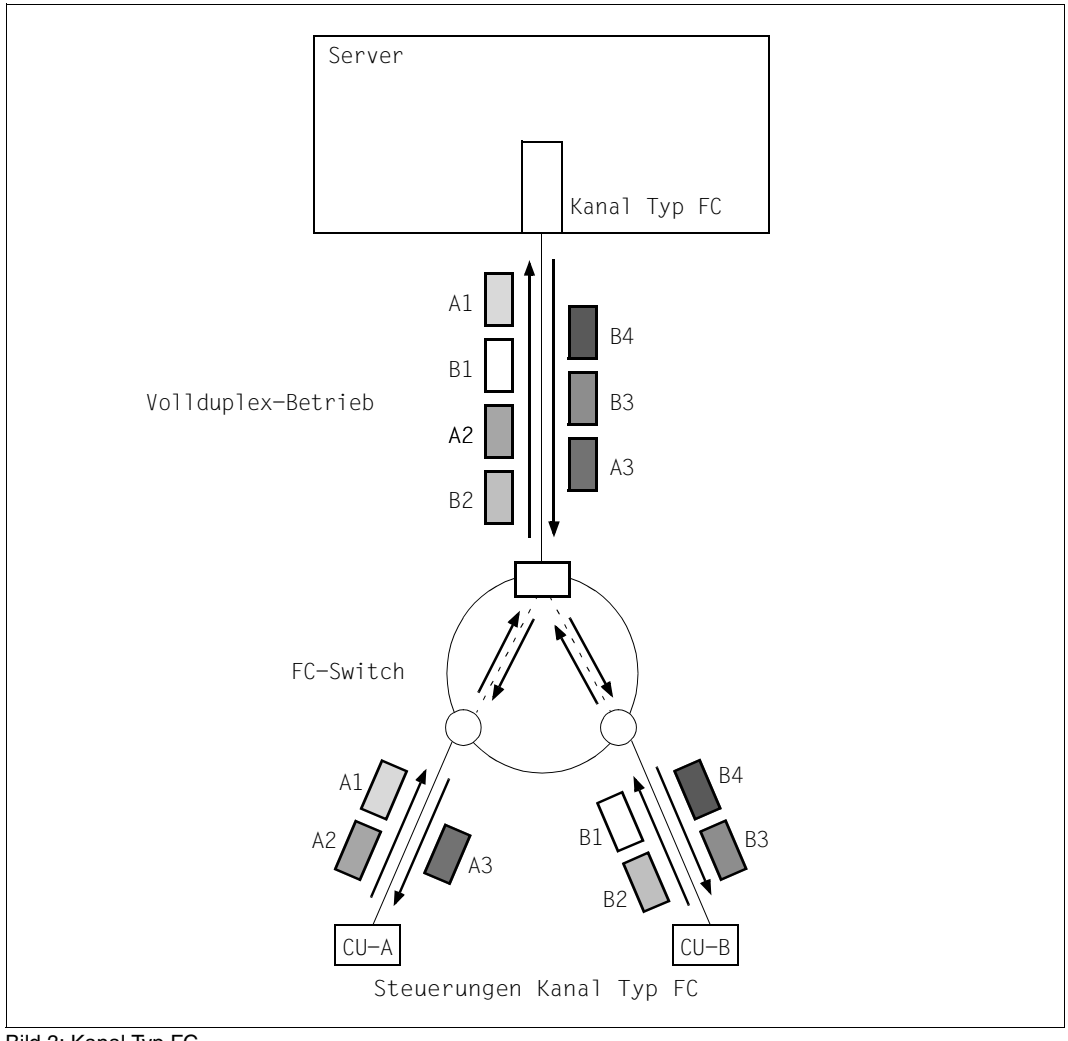

Bild 3: Kanal Typ FC

Zusammen mit einem Symmetrix-System DMX-3, Random-Zugriffen mit 25% Schreibanteil und 100% Read-Hit-Rate schafft ein Kanal Typ FC eines Servers S190 abhängig von der Blockgröße und vom Datenformat maximal folgende Ein-/Ausgabe- bzw. Durchsatzraten:

Blockgröße	**Datenformat NK2**	
	Ein-/Ausgaben pro Sekunde	**Mbyte pro Sekunde**
2 KB	9.400	19
4 KB	9.100	37
8 KB	8.200	67
16 KB	5.600	90
32 KB	3.300	110
160 KB	700	115

Die Ergebnisse für ein Symmetrix-System DMX-4 oder V-Max (siehe Seite 74) sind vergleichbar.

Bei den verwendeten Random-Zugriffen mit 25% Schreibanteil kann die Duplex-Eigenschaft des FC-Kanals ausgenutzt werden. Bei reinem Lesen oder Schreiben können mehr als 90 Mbyte/s erreicht werden.

Fibre Channel Anschlüsse skalieren sehr gut. Das heißt, mit n Kanälen Typ FC kann annähernd der n-fache Durchsatz erreicht werden. Voraussetzung dafür ist eine ausreichende Leistung der BS2000-CPUs und der Peripherie.

Sollen hoch ausgelastete Kanäle (> 60%) vom Typ S durch einen Kanal Typ FC ersetzt werden, so kann die Anzahl ersetzbarer Kanäle vom Typ S in Abhängigkeit von der Blockgröße anhand der folgenden Grafik abgeschätzt werden:

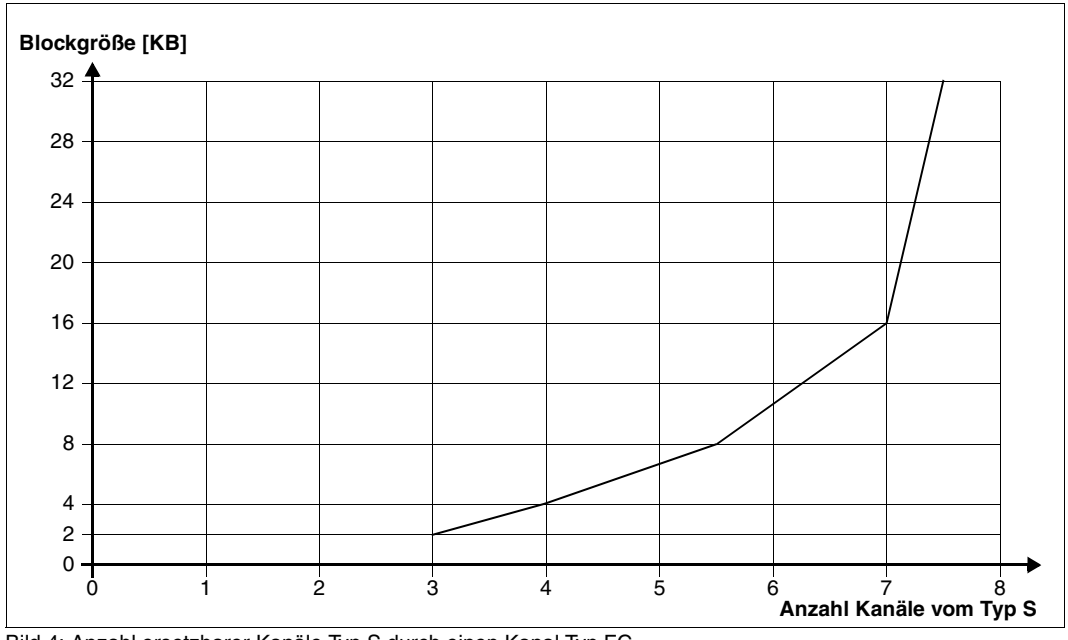

Bild 4: Anzahl ersetzbarer Kanäle Typ S durch einen Kanal Typ FC

Bei Transaktions-orientierten Lastfällen können also etwa 4 Kanäle Typ S durch einen Kanal Typ FC ersetzt werden. Bei Durchsatz-orientierten Lastfällen können bis zu 7 Kanäle Typ S durch einen Kanal Typ FC ersetzt werden.

i Durch die parallele Abwicklung von bis zu acht Kanalprogrammen kann die Auslastung eines Kanals Typ FC nicht direkt mit openSM2 gemessen werden. Die Auslastung wird daher indirekt bestimmt, indem die aktuelle Anzahl Ein-/Ausgabe-Operationen mit einem Durchsatzwert verglichen wird, der bei Labormessungen maximal erreicht werden konnte.

3.3.2 Ein-/Ausgabe auf SX-Servern

An den SX-Servern können Geräte über lokale SCSI-Verbindungen und über externe Fibre Channel-Verbindungen (FC-Peripherie) betrieben werden.
Die Ein-/Ausgabe auf FC-Peripherie erfolgt über den I/O-Prozessor und die PCI-(FC-)Controller des SX-Servers.

3.3.2.1 I/O-Prozessor (X2000)

Alle Ein-/Ausgaben zur Peripherie werden über den I/O-Prozessor (X2000) geleitet. Die entsprechenden Schnittstellen werden in X2000 bedient.

Der Anschluss der Peripherie erfolgt über PCI-Controller:

- Fibre Channel:
  Anschluss von Plattenspeichersystemen (FibreCAT CX (CLARiiON CX), Symmetrix), MBK-Peripherie (z.B. FibreCAT TX24, Scalar 10K, i500, i2000, MBK 3591), ETERNUS CS (CentricStor)
- LAN-Controller (Ethernet, Fast Ethernet, Gigabit Ethernet)
- UHPS (Universal Hot Plug System): Anschluss von Kanal-Peripherie (z.B. alte Magnetbandkassettengeräte oder Drucker)
- SCSI: interne Platten, FibreCAT TX24

Die Leistung der Peripherie hängt damit nicht nur von den Geräten und deren Anschluss ab, sondern auch von der X2000-Leistung.

3.3.2.2 FC-Anschluss

Auf SX-Servern können auch PCI-(FC-)Controller mit bis zu 4 Gbit/s eingesetzt werden.

Bei Platten-Ein-/Ausgaben über FC schafft ein I/O-Prozessor auf einem Server SX160 bei Random-Zugriffen mit 25% Schreibanteil und 100% Read-Hit-Rate folgende maximale Ein-/Ausgabe- bzw. Durchsatz-Raten:

Blockgröße	Datenformat NK	
	Ein-/Ausgaben pro Sekunde	Mbyte pro Sekunde
2 KB	23.500	45
4 KB	20.000	80
8 KB	16.000	130
16 KB	11.000	180
32 KB	5.500	180
160 KB	1.400	230

Die Leistung des I/O-Prozessors ist auch für hohe Ein-/Ausgabe-Lasten selbst auf dem größten SX-Server ausreichend.

Bei den Servern SX100 erreicht der Ein-/Ausgabe-Prozessor ebenfalls Ein-/Ausgaberaten, die weit über den üblichen Ein-/Ausgabe-Lasten dieser Modelle liegen.

3.3.2.3 Kanal Typ S

Da die Leistung eines I/O-Prozessors mit FC-Peripherie deutliche Performance-Vorteile gegenüber Kanal-Peripherie hat, wird empfohlen die Platten-Peripherie möglichst über Kanal Typ FC anzuschließen. (Auf Servern SX160 wird der Anschluss über Kanal Typ S nur noch als Sonderfreigabe angeboten.)

Die maximale Datenrate eines Kanals Typ S liegt bei 17 Mbyte/s.

Bei Platten-Ein-/Ausgaben über Kanäle vom Typ S schafft ein I/O-Prozessor auf einem Server SX150 beim Lesen folgende maximale Ein-/Ausgabe- bzw. Durchsatz-Raten:

Blockgröße	Datenformat K	
	Ein-/Ausgaben pro Sekunde	Mbyte pro Sekunde
2 KB	7.600	16
4 KB	7.000	29
8 KB	5.800	47
16 KB	4.800	79
32 KB	3.800	124

Abhängig von der Blockgröße und vom Datenformat schafft ein Kanal vom Typ S beim Lesen aus einem Cache maximal folgende Ein-/Ausgabe- bzw. Durchsatzraten:

Blockgröße	Datenformat K		Datenformat NK4	
	Ein-/Ausgaben pro Sekunde	Mbyte pro Sekunde	Ein-/Ausgaben pro Sekunde	Mbyte pro Sekunde
2 KB	600	1,2	-----	------
4 KB	510	2,1	570	2,3
8 KB	400	3,3	480	3,9
16 KB	270	4,4	330	5,4
32 KB	170	5,6	210	6,9

Aus Performance-Gründen sollte eine Kanal-Auslastung von 60% nicht überschritten werden.

Beim Wechsel von einem S-Server auf einen SX-Server mit Kanalanschluss (z.B. SX150) kann zur Bewältigung des Ein-/Ausgabe-Durchsatzes eine Erhöhung der Anzahl Kanäle erforderlich sein.

Kanaladapter für Magnetbandkassetten können auf SX-Servern nahezu ohne Performance-Minderung eingesetzt werden.

3.3.2.4 Interne Platten

Interne, über SCSI angeschlossene Platten sollten nicht für performance-kritische Anwendungen eingesetzt werden.

Da sie im Unterschied zu Plattenspeichersystemen (z.B. FibreCAT CX) keinen Cache, sondern nur den relativ kleinen Platten-Cache haben, entsprechen die Hardware-Bedienzeiten bei Random-Zugriffen oder bei sequenziellen Schreib-Zugriffen fast denen eines Cache-Miss bei Plattenspeichersystemen. Nur beim sequenziellen Lesen mit einem Task kann durch die „read-ahead"-Strategie der Platte ein sehr guter Durchsatz erreicht werden.

Zur Verbesserung der Performance für die internen SCSI-Plattensubsysteme wird der Einsatz des Softwareprodukts DAB empfohlen.

3.3.3 Ein-/Ausgabe auf SQ-Servern

An den SQ-Servern können Geräte über lokale SAS bzw. SCSI-Verbindungen und über externe Fibre Channel-Verbindungen (FC-Peripherie) betrieben werden.
Die Ein-/Ausgabe auf FC-Peripherie erfolgt über I/O-Prozessoren und die PCI-(FC-)Controller des SQ-Servers.

3.3.3.1 I/O-Prozessoren (X2000)

Alle Ein-/Ausgaben zur Peripherie werden über die I/O-Prozessoren (X2000) geleitet. Die entsprechenden Schnittstellen werden in X2000 bedient.

Der Anschluss der Peripherie erfolgt über PCI-Controller:

- SAS:
  Anschluss der internen Systemplatten (nicht zur Nutzung unter BS2000/OSD freigegeben), des internen Plattenspeichersystems FibreCAT SX40 und des internen MBK-Systems ETERNUS LT40 (FibreCAT TX24 S2)
- Fibre Channel:
  Anschluss der externen Plattenspeichersysteme
  FibreCAT CX (CLARiiON CX) und Symmetrix DMX, V-Max,
  Anschluss der MBK-Peripherie ETERNUS LT40 (FibreCAT TX24 S2),
  Scalar 10K, i500, i2000, ETERNUS CS (CentricStor)
- LAN-Controller (Ethernet, Fast Ethernet, Gigabit Ethernet)
- SCSI: interne Laufwerke (DVD-RW und LTO)

Die Leistung der I/O-Prozessoren ist sehr gut und für alle SQ100-Modelle ausreichend:

- Platten
  Die maximale IO-Rate liegt bei 25.000 IO/s (bis Blockgrößen von 8 KByte).
  Der maximale Durchsatz bei 600 Mbyte/s (bei Blockgrößen ab 32 KByte).
- Bänder
  Die Ein-/Ausgabe auf Band wurde im I/O-Prozessor optimiert und erheblich verbessert.
  Der Durchsatz auf ein leistungsfähiges Band (z.B. auf ETERNUS CS (CentricStor)) liegt bei 200 Mbyte/s.
- Networking
  Auf der SQ100-40D wird eine maximale Transaktionsrate von 10.000 TA/s erreicht.
  Der maximale Durchsatz liegt mit Standard-Frames bei 60 Mbyte/s,
  bei Jumbo-Frames bei 110 Mbyte/s.
  Um Hochleistungsnetze ausnutzen zu können, ist eine ausreichende CPU-Kapazität erforderlich. Die Transaktionsrate ist nur durch die BS2000-CPUs begrenzt.

3.3.3.2 SAS-Anschluss

Bei Platten-Ein-/Ausgaben über SAS (Plattenspeichersystem FibreCAT SX40) schafft ein I/O-Prozessor auf einem Server SQ100 bei Random-Zugriffen mit 25% Schreibanteil und 100% Read-Hit-Rate folgende maximale Ein-/Ausgabe- bzw. Durchsatz-Raten:

Blockgröße	Datenformat NK	
	Ein-/Ausgaben pro Sekunde	Mbyte pro Sekunde
2 KB	25.000	50
4 KB	25.000	100
8 KB	25.000	200
16 KB	23.000	360
32 KB	19.000	600

Die Leistung eines I/O-Prozessors ist auch für hohe Ein-/Ausgabe-Lasten selbst auf dem größten SQ100-Server ausreichend.

Beim Einsatz des optionalen, über SAS-RAID angeschlossenen Plattensystems FibreCAT SX40 mit Backup Battery Unit (BBU) für den Write-Cache wird standardmäßig alle 30 Tage ein BBU Relearn Cycle durchgeführt. Der BBU Relearn Cycle dauert bis zu 15 Stunden. Er entlädt und lädt die BBU mehrfach vollständig. Während dieser Zeit ist der Write-Cache ausgeschaltet; der damit verbundene zusätzliche Beschleunigungseffekt entfällt. Das kann bei bestimmten Anwendungen zu höheren Lauf- bzw. Antwortzeiten führen. Der BBU Relearn Cycle kann durch den Service kundenspezifisch konfiguriert werden, so dass z.B. der BBU Relearn Cycle stets nur an einem Wochenende ausgeführt wird.

3.3.3.3 FC-Anschluss

Auf SQ-Servern können auch PCI-(FC-)Controller mit bis zu 4 Gbit/s eingesetzt werden.

Bei Platten-Ein-/Ausgaben über FC ist die Leistung eines I/O-Prozessors auf einem Server SQ100 vergleichbar mit den Messwerten des SAS-Anschlusses.

Die Leistung eines I/O-Prozessors ist auch für hohe Ein-/Ausgabe-Lasten selbst auf dem größten SQ-Server ausreichend.

3.4 Migration

Dieser Abschnitt behandelt die Fragen:

- Was ist beim Umstieg auf SX- oder SQ-Server zu beachten?
- Welcher Server ist für die Migration geeignet (RPF-Leistung)?

Der Ausgangszustand im momentanen Betrieb ist die Basis für die Betrachtungen. Dazu müssen die wichtigsten Anwendungsfälle wie OLTP-Betrieb oder kritische Batch-Anwendungen auf dem Ausgangs-Server mit openSM2 vermessen werden. Anschließend erfolgt die Auswertung der Ergebnisse und eine Prognose welcher Ziel-Server geeignet ist.

Generell ist bei einem Server-Wechsel zu beachten:

- Derzeitige CPU-Auslastung des Ausgangs-Servers (hoch / niedrig)
  Im OLTP-Betrieb sollten die CPUs des Servers weniger als 70% ausgelastet sein.
  Im Batch-Betrieb sind meist bis 100% CPU-Auslastung vertretbar.
- Einplanung des CPU-Mehrbedarfs bei BS2000/OSD-Versionswechsel
  Der Mehrbedarf ist versionsabhängig. Im Mittel sind 1 - 2% pro Version anzusetzen.
- Berücksichtigung des eigenen Wachstumsbedarfs
  Beispiel: jeweils 5% für 3 Jahre, ergibt etwa 15% Wachstumsbedarf.
- Einfluss von Neuaufnahmen oder Verlagerungen von Anwendungen
  Wenn auf dem neuen Server Anwendungen wegfallen bzw. neu hinzukommen, dann muss das berücksichtigt werden.

Bei Bedarf wird empfohlen, das Angebot des BS2000/OSD-Democenters zu nutzen:

- Performanceberatung bei der Migration
- Testmessungen von Kundenanwendungen auf der Ziel-Hardware

3.4.1 Migration von S-Servern auf SX-Server

Folgendes ist zu beachten:

- Mono-Leistung
  Wenn von einem S-Server (Monoprozessor) auf einen SX-Server (Multiprozessor) migriert werden soll, dann kann der Gesamt-RPF-Wert zwar gleich bleiben, die Monoprozessor-Leistung wird aber kleiner sein. Dies ist zu berücksichtigen, z.B. bei Batch-Anwendungen, die nicht parallel betrieben werden können.

- CPU-Leistung: TU-Anteil
  Wie im Abschnitt „CPU-Leistung von SX-Servern“ auf Seite 31 erklärt, sorgt die CISC-Firmware dafür, dass Kunden-Anwendungen auf SX-Servern unverändert ablaufen. Der RPF-Wert des SX-Servers gilt für einen TU-Anteil von 40 - 50% am Gesamt-CPU-Bedarf. Je nach TU-Anteil am S-Server, der mit openSM2 gemessen werden kann, ist beim RPF-Wert des SX-Servers noch folgender Faktor zu berücksichtigen:

  – TU-Anteil 30%: Faktor ca. 0,9
  – TU-Anteil 40%: Faktor ca. 1,0
  – TU-Anteil 50%: Faktor ca. 1,1
  – TU-Anteil 60%: Faktor ca. 1,2

- CPU-Leistung: Positive Sondereinflüsse
  Ein zusätzlicher Leistungsgewinn entsteht auf SX-Servern, wenn Programme ablaufen, die direkt auf dem SX-Server (ohne CISC-Firmware) ablaufen können („asstranierte“ Programme), z.B. bei SESAM (10 - 30%) oder mit optimiertem Compiler erstelltes ORACLE (bis über 50%).

- CPU-Leistung: Negative Sondereinflüsse

  Beispiele

  – intensive Nutzung von Dezimal-, Floatingpoint- oder EX-Befehlen
  – selbstmodifizierender Code
  – Code und Daten gemischt auf derselben Speicherseite
  – Ausrichtungsverstöße

- Peripherie: Kanäle Typ S
  SX-Server sind nicht für Kanal Typ S optimiert (siehe Seite 46).
  Es wird dringend empfohlen, auf SX-Servern Kanäle Typ FC (und Plattentyp D3435, Plattenformat FBA) zu verwenden.
  Falls die Kanal-Peripherie trotzdem beibehalten werden muss, z.B. während einer Migrationsphase, sind ggf. mehr Kanäle Typs S als auf dem S-Server notwendig.
  Eine Analyse des Bedarfs wird empfohlen.

- Peripherie: Networking
  Es wird der Einsatz der integrierten LAN-Controller der SX-Server empfohlen.
  Von der Weiterverwendung des HNC über Kanal Typ S wird abgeraten.

- Speicherbedarf
  In aller Regel ist der Standard-Hauptspeicherausbau der SX-Server ausreichend.
  Zu Ausnahmen siehe den Abschnitt „Hauptspeicher auf SX-Servern“ auf Seite 38.

Beispiel: Berechnung des RPF-Werts für einen Ziel-SX-Server

Für den bisher genutzten S-Server sollen folgende Annahmen gelten:

- S135-10B (72 RPF)
- Last: OLTP-Betrieb (UTM/SESAM)
- CPU-Auslastung 80% (davon 50% TU)
- BS2000/OSD V7.0
- Wachstumsbedarf 15%

Damit ergibt sich folgende Rechnung für den Ziel-SX-Server:

72 RPF * 1.1 (TU-Anteil 50%) * 1.02 (Übergang von BS2000/OSD V7.0 nach V8.0) * * 0.8 (asstraniertes SESAM) = 65 RPF

Um die Auslastung trotz Wachstum bei den für TP-Betrieb empfohlenen 65% zu halten:

65 RPF * 1.2 (Ziel-Auslastung 65%) * 1.15 (Wachstumsbedarf) = 90 RPF

D.h. ein Server SX160-10C mit 105 RPF wäre geeignet.

3.4.2 Migration von S-Servern auf SQ-Server

Folgendes ist zu beachten:

- Mono-Leistung
  Wenn von einem S-Server (Monoprozessor) auf einen SQ-Server (Multiprozessor) migriert werden soll, dann kann der Gesamt-RPF-Wert zwar gleich bleiben, die Monoprozessor-Leistung wird aber kleiner sein. Dies ist zu berücksichtigen, z.B. bei Batch-Anwendungen, die nicht parallel betrieben werden können.
- CPU-Leistung: TU-Anteil
  Wie im Abschnitt „CPU-Leistung von SQ-Servern“ auf Seite 33 erklärt, sorgt die CISC-Firmware dafür, dass Kunden-Anwendungen auf SQ-Servern unverändert ablaufen. Der RPF-Wert des SQ-Servers gilt für einen TU-Anteil von 40 - 50% am Gesamt-CPU-Bedarf. Je nach TU-Anteil am S-Server, der mit openSM2 gemessen werden kann, ist beim RPF-Wert des SQ-Servers noch folgender Faktor zu berücksichtigen:
  - TU-Anteil 30%: Faktor ca. 0,9
  - TU-Anteil 40%: Faktor ca. 1,0
  - TU-Anteil 50%: Faktor ca. 1,1
  - TU-Anteil 60%: Faktor ca. 1,2
- CPU-Leistung: Negative Sondereinflüsse

  Beispiele

  - intensive Nutzung von Dezimal-, Floatingpoint- oder EX-Befehlen
  - selbstmodifizierender Code
  - Code und Daten gemischt auf derselben Speicherseite
  - Ausrichtungsverstöße
- Peripherie: keine Kanäle
  Auf SQ-Servern stehen keine Kanäle zur Verfügung. Aus Performance-Sicht ist eine Umstellung auf SAS oder Fibre Channel vorteilhaft.
  Eine Datenmigration kann erforderlich sein, siehe Handbuch „Migration Guide“ [18].
- Peripherie: Networking
  Es stehen die integrierten LAN-Controller des SQ-Servers zur Verfügung.
  Ein HNC ist nicht erforderlich und kann auch nicht verwendet werden.
- Speicherbedarf
  In aller Regel ist der Standard-Hauptspeicherausbau der SQ-Server ausreichend.
  Zu Ausnahmen siehe den Abschnitt „Hauptspeicher auf SQ-Servern“ auf Seite 39.

Beispiel: Berechnung des RPF-Werts für einen Ziel-SQ-Server

Für den bisher genutzten S-Server sollen folgende Annahmen gelten:

- S135-10B (72 RPF)
- Last: OLTP-Betrieb (UTM/SESAM)
- CPU-Auslastung 80% (davon 50% TU)
- BS2000/OSD V7.0
- Wachstumsbedarf 15%

Damit ergibt sich folgende Rechnung für den Ziel-SQ-Server:

72 RPF * 1.1 (TU-Anteil 50%) * 1.02 (Übergang von BS2000/OSD V7.0 nach V8.0) = = 80 RPF

Um die Auslastung trotz Wachstum bei den für TP-Betrieb empfohlenen 65% zu halten:

80 RPF * 1.2 (Ziel-Auslastung 65%) * 1.15 (Wachstumsbedarf) = 110 RPF

D.h. ein Server SQ100-20D mit 110 RPF wäre geeignet.
Zu beachten ist dabei der Wechsel von einem Monoprozessor auf einen Multiprozessor mit zwei CPUs.

3.4.3 Migration von SX-Servern auf SQ-Server

Folgendes ist zu beachten:

- Mono-Leistung
  Wenn von einem SX-Server (Monoprozessor) auf einen SQ-Server (Multiprozessor) migriert werden soll, dann kann der Gesamt-RPF-Wert zwar gleich bleiben, die Monoprozessor-Leistung wird aber kleiner sein. Dies ist zu berücksichtigen, z.B. bei Batch-Anwendungen, die nicht parallel betrieben werden können.
- CPU-Leistung: TU-Anteil
  Wie in den Abschnitten „CPU-Leistung von SX-Servern“ auf Seite 31 und „CPU-Leistung von SQ-Servern“ auf Seite 33 erklärt, sorgt die CISC-Firmware dafür, dass Kunden-Anwendungen auf SX und SQ-Servern unverändert ablaufen. Der RPF-Wert des SQ-Servers gilt für einen TU-Anteil von 40 - 50% am Gesamt-CPU-Bedarf.
- CPU-Leistung: Negative Sondereinflüsse

  Beispiele

  – intensive Nutzung von Dezimal-, Floatingpoint- oder EX-Befehlen
  – selbstmodifizierender Code
  – Code und Daten gemischt auf derselben Speicherseite
  – Ausrichtungsverstöße
- Peripherie: keine Kanäle
  Auf SQ-Server stehen keine Kanäle zur Verfügung. Aus Performance-Sicht ist eine Umstellung auf SAS oder Fibre Channel vorteilhaft.
  Eine Datenmigration ist normalerweise nicht erforderlich, siehe Handbuch „Migration Guide“ [18].
- Peripherie: Networking
  Es stehen die integrierten LAN-Controller des SQ-Servers zur Verfügung.
  Ein HNC ist nicht erforderlich und kann auch nicht verwendet werden.
- Speicherbedarf
  In aller Regel ist der Standard-Hauptspeicherausbau der SQ-Server ausreichend.
  Zu Ausnahmen siehe den Abschnitt „Hauptspeicher auf SQ-Servern“ auf Seite 39.

Beispiel: Berechnung des RPF-Werts für einen Ziel-SQ-Server

Für den bisher genutzten SX-Server sollen folgende Annahmen gelten:

- SX130-10C (50 RPF)
- Last: OLTP-Betrieb (UTM/SESAM)
- CPU-Auslastung 80% (davon 50% TU)
- BS2000/OSD V7.0
- Wachstumsbedarf 15%

Damit ergibt sich folgende Rechnung für den Ziel-SQ-Server:

`50` RPF `* 1.02` (Übergang von BS2000/OSD V7.0 nach V8.0) `* 1.15` (Wachstumsbedarf) `= 59` RPF

D.h. ein Server SQ100-10D mit 60 RPF wäre geeignet.

4 Leistungsverhalten der Peripherie

4.1 Eigenschaften von Plattenspeichersystemen

Dieser Abschnitt beschreibt die performance-relevanten Eigenschaften folgender Plattenspeichersysteme, soweit sie zum Verständnis ihres Leistungverhaltens aus Sicht von BS2000/OSD notwendig sind:

- Symmetrix 8000, DMX und V-Max beim Anschluss an S-Server
- FibreCAT CX (CLARiiON CX), Symmetrix DMX und V-Max beim Anschluss an SX- und SQ-Server

4.1.1 Komponenten von Plattenspeichersystemen

Die wichtigsten, performance-relevanten Komponenten der Plattenspeichersysteme sind:

- Server-Anschluss
- Cache
- Platten
- Controller

Server-Anschluss

FibreCAT CX oder Symmetrix-Plattenspeichersysteme werden an einen BS2000/OSD-Server angeschlossen über

- Kanal Typ S (S- und SX-Server, Datenrate 17 Mbyte/s) oder
- Kanal Typ FC (S-Server, Datenrate 1 Gbit/s) bzw.
  FC-Anschluss (SX- und SQ-Server, Datenrate 1 bis 4 Gbit/s)

Die Anzahl benötigter Anschlüsse ist vom Ausbau des Plattenspeichersystems abhängig. Der Anschluss über mehrere Pfade muss bei Kanälen berücksichtigt werden.
Aus Performancesicht sind uneingeschränkt Kanäle vom Typ FC bzw. FC-Anschlüsse zu empfehlen.

Die Leistung der Kanäle bzw. der I/O-Prozessoren bei SX- und SQ-Servern ist im Kapitel „Leistungsverhalten der Server“ auf Seite 27 beschrieben.

Cache

Die Komponente eines Plattenspeichersystems mit dem größten Einfluss auf die Performance ist der Cache. Jede Ein-/Ausgabe-Anforderung unterliegt dem Caching. Die Hardware-Bedienzeit (I/O-Zeit) hängt wesentlich davon ab, ob sich die Daten im Cache befinden oder ob sie erst von der Platte gelesen bzw. dorthin transferiert werden müssen.

Falls sich beim Lesen der gesuchte Datenblock nicht im Cache befindet, muss er von den Platten gelesen werden (Read-Miss). Ein solcher Read-Miss kostet erheblich mehr Zeit als ein Read-Hit, bei dem sich die Daten schon im Cache befinden. Beim Erkennen sequenzieller Verarbeitung erfolgt ein Lesen von Daten im Voraus (Read Ahead), um einen Read-Miss zu vermeiden.

Da der Cache der Plattenspeichersysteme durch Batterien gegen Stromausfall gesichert ist, gelten Schreib-Aufträge als beendet, wenn sie in den Cache geschrieben und verifiziert sind (Write-Hit-Rate = 100 %). Eine Schreib-Ein-/Ausgabe dauert also annähernd so lange wie ein Read-Hit. Das Schreiben auf Platte erfolgt asynchron zur Ein-/Ausgabe. Falls im Cache nicht genügend Platz ist, treten so genannte „Delayed Fast Writes“ auf, d.h. Cache-Inhalte müssen zuerst gesichert werden, bevor die Einlagerung neuer Daten in den Cache möglich ist (Write-Hit-Rate < 100 %). Dies tritt typischerweise bei der Rekonstruktion großer Datenmengen auf.

Als Hit-Rate wird der Anteil der Cache-Hits an der Gesamtzahl der Ein-/Ausgaben auf das Plattenspeichersystem bezeichnet. Teilweise wird noch unterschieden zwischen der Read-Hit-Rate und der Total-Hit-Rate. In der Total-Hit-Rate sind die Cache Write-Hits enthalten. In diesem Handbuch werden nur Read-Hit-Raten betrachtet.
Hersteller von Plattenspeichersystemen geben oft die „Total-Hit-Rate“ an, die auch die Cache Write-Hits beinhaltet und damit höher ist als die hier betrachtete Read-Hit-Rate.

Durch den Einsatz großer Caches kann auch für Lese-Anforderungen eine hohe Hit-Rate (> 90 %) erreicht werden. Eine gute Leistung eines Plattenspeichersystems wird normalerweise ab einer Read-Hit-Rate von 80 % erreicht.

Für die Caches der Plattenspeichersysteme gibt es eine Vielzahl von Konfigurationsmöglichkeiten. Sie sind in der Dokumentation der Hersteller beschrieben.

Platten

Von physikalischen Platten sind meist bekannt:

- Speicherkapazität (in Gbyte, z.B. 300 Gbyte)
- Umdrehungsgeschwindigkeit (in „rotations per minute“, z.B. 15.000 rpm).

Weiterhin sind für die Leistung einer Platte bestimmend:

- Plattenspeichersystem-interner Anschluss mit Anschlussart (z.B. Fibre Channel, SAS, Serial ATA (SATA)) und Übertragungsgeschwindigkeit (z.B. 2 oder 4 Gbit/s)
- Cache auf dem Laufwerk (Laufwerks-Cache)

Ein Anwender sieht die Leistung der physikalischen Platten in der Regel nur bei einem Read-Miss.

Aus Sicht von BS2000/OSD bestehen bei den heute angebotenen Plattengrößen keine Einschränkungen für deren Verwendung.

i Die Daten performance-kritischer Anwendungen sollten **nicht** auf SATA-Platten gelegt werden.

Controller

Die Controller der Plattenspeichersysteme bearbeiten die Ein-/Ausgabe-Anforderungen des Servers, steuern den Cache-Zugriff und wickeln den Zugriff zu den physikalischen Plattenlaufwerken ab.

Die Anzahl der Controller sowie die Anzahl der Wege zu den bedienten Servern und zu den internen Platten sind modellabhängig.

Auch die Aufgabenverteilung der Controller ist modellabhängig. Auf Symmetrix-Plattenspeichersystemen gibt es z.B. Channel-Directors für den Server-Zugriff und Disk-Directors für den Zugriff zu den Platten. Auf FibreCAT CX werden beide Aufgaben durch (zwei) Service Prozessoren ausgeführt.

Die Firmware der Controller hat einen erheblichen Einfluss auf die Performance. Normalerweise wird ein Umstieg auf den jeweils aktuellsten Stand empfohlen.

4.1.2 Konfigurierung von Plattenspeichersystemen

Dieser Abschnitt beschreibt die performance-relevanten Aspekte der Konfigurierung eines Plattenspeichersystems soweit sie aus Sicht von BS2000/OSD wichtig sind.

RAID-Gruppen und LUNs

Mehrere Platten werden bei der Konfigurierung zu RAID-Gruppen zusammengefasst. Diese RAID-Gruppen haben ein einheitliches Plattenformat (FBA, CKD) und einen RAID-Level (RAID1, RAID1/0, RAID5, RAID6).

Auf diesen RAID-Gruppen werden so genannte Logical Unit Numbers (LUNs) definiert. Es ist zulässig, und bei großen Platten auch wahrscheinlich, dass mehrere LUNs (logische Volumes) auf derselben physikalischen Platte eingerichtet werden. Zu den Auswirkungen logischer Volumes auf die Performance siehe „Logische Volumes und physikalische Platten“ auf Seite 66.

Die Konfigurierung im BS2000/OSD verwendet diese LUNs mit LUN-Nummern, Plattentyp (z.B. D3435, D3475-8F, D3490) und Plattenformat (CKD, FBA).

Plattenformat und Plattentyp

Beim Anschluss eines Plattenspeichersystems Symmetrix über Kanal Typ S (S- und SX-Server) wird sowohl das CKD-Format (Count Key Data, Plattentyp D3490), als auch das FBA-Format (Fixed Block Architecture, Plattentyp D3435) unterstützt.

Beim Anschluss von Plattenspeichersystemen über Kanal Typ FC bzw. FC-Anschluss (Symmetrix, FibreCAT CX) können die Platten ausschließlich im FBA-Format mit den Plattentypen D3475-8F (nur SX- und SQ-Server) und D3435 (alle BS2000/OSD-Server) eingerichtet werden. Beim Plattentyp D3475-8F können bis zu sieben BS2000-Volumes pro LUN konfiguriert werden, beim Plattentyp D3435 genau ein Volume.

Der empfohlene Plattentyp ist D3435:

- Dieser Plattentyp **muss** verwendet werden
  - bei Anschluss von Plattenspeichersystemen über Kanal Typ FC an S-Servern
  - bei gemeinsamer Nutzung von Fibre Channel-Platten zusammen mit S-Servern
- Dieser Plattentyp wird empfohlen bei Anschluss an Kanal Typ S (an Stelle von D3490) wegen der höheren Kapazität und der leicht möglichen Migration zu Kanal Typ FC bzw. zum FC-Anschluss

- Dieser Plattentyp wird empfohlen für SX- und SQ-Server (an Stelle von D3475-8F) wegen der Spiegelungsfunktionen der Plattenspeichersysteme und der möglichen gemeinsamen Nutzung mit S-Servern. Die Spiegelungsfunktionen MirrorView/Snapview bei FibreCAT CX-Plattenspeichersystemen bzw. SRDF und TimeFinder bei Symmetrix-Plattenspeichersystemen arbeiten auf LUN-Ebene, deshalb ist der Plattentyp D3475-8F dafür ungeeignet.
- Wenn eine Symmetrix-Platte mit FBA-Format heute am Kanal Typ S betrieben wird, dann kann diese Platte auf einen Kanal Typ FC oder einen FC-Anschluss umkonfiguriert werden, ohne die Daten zu verändern. Sie wird dann als Platte vom Typ D3435 weiter betrieben. Diese Eigenschaft ist beim Umstieg von einem S-Server auf einen SX- oder SQ-Server nützlich, da dann keine Datenmigration erforderlich ist.
  Bei gemeinsamer Nutzung kann diese Platte aber nur von den Servern betrieben werden, an denen sie über Kanal Typ FC bzw. den FC-Anschluss angeschlossen ist.

Generell ergibt sich für das FBA-Format eine bessere Nutzung der Cache- und Plattenkapazität als für das CKD-Format.
Unter Performance-Gesichtspunkten sind die Unterschiede zwischen CKD- und FBA-formatierten Platten am Kanal Typ S gering.

4.1.2.1 RAID-Level

Alle Symmetrix- und FibreCAT CX-Systeme sind hochverfügbare Plattenspeichersysteme, die neben den ursprünglich von der Berkeley University definierten RAID-Standards auch alle vom „RAID Advisory Board“ festgelegten Verfügbarkeitsstufen erfüllen. Sie unterscheiden sich lediglich in den Ausbaumöglichkeiten. Der RAID-Level bezeichnet die Methode zur Bildung fehlertoleranter und performanter Plattenspeichersysteme. Bei den Plattenspeichersystemen für BS2000/OSD sind die folgenden RAID-Level üblich:

- RAID1 (full mirror)
- RAID1/0 (striping + full mirror)
- RAID5 (striping + parity mirror)
- RAID6 (striping + dual parity mirror)

RAID1

Jeweils zwei identische Plattenlaufwerke, Original- und Spiegelplatte, bilden eine RAID1-Gruppe (Kurzbezeichung im Folgenden „RAID1(1+1)“).

Sie enthalten identische Daten. Damit stehen für den Anwender nur 50% der Plattenkapazität zur Verfügung. Die Schreibleistung ändert sich durch die Spiegelung nicht. Bei Leseaufträgen versucht das Plattenspeichersystem zu optimieren und von der günstigeren Platte zu lesen. Bei Ausfall einer Platte kann bis zum Ersatz der Platte weitgehend ohne Performanceverlust weitergearbeitet werden.

RAID1/0

Gegenüber RAID1 erfolgt bei RAID1/0 eine zusätzliche Verteilung der Daten über mehrere Platten in Form des „data striping“. Eine RAID1/0-Gruppe besteht also aus mehreren, oft 4 Platten, auf denen die Originaldaten mit „data striping“ verteilt sind. Dazu kommen ebenso viele Platten mit den gespiegelten Daten (Kurzbezeichung im Folgenden z.B. „RAID10(4+4)“).

Auf Symmetrix-Systemen ist für RAID1/0 auch der Begriff „Meta Volumes“ üblich. Wie bei RAID1 steht dem Anwender nur 50% der installierten Plattenkapazität zur Verfügung. Allerdings bietet die Datenspiegelung mit RAID1/0 durch Erhöhung der Parallelität beim Datenzugriff und durch gleichmäßigere Auslastung der Platten die beste Performance. Bei RAID1/0 können bei geringem Performanceverlust sogar mehrere Platten ausfallen, solange nicht Originalplatte und Spiegelplatte gleichzeitig ausfallen.

RAID5

RAID5 realisiert eine gemeinsame Parity-Sicherung für mehrere Plattenlaufwerke. Die Daten werden wie bei RAID1/0 mit „data striping“ in Blöcken über die Plattenlaufwerke der RAID5-Gruppe verteilt und mit der Parity-Information, ebenfalls verteilt über alle Laufwerke, gesichert („rotating parity“). Da beim Schreiben zusätzlich die Parity-Infomationen berechnet und geschrieben werden müssen, ist RAID5 etwas aufwändiger als RAID1/0. Durch das „data striping“ bietet es aber wie RAID1/0 die Vorteile bei parallelen Zugriffen.

Eine RAID5-Gruppe besteht häufig aus 4 Platten, dabei stehen drei Viertel der Gesamtkapazität für Benutzerdaten zur Verfügung, Ein Viertel der Kapazität wird für die Parity-Informationen genutzt (Kurzbezeichung im Folgenden „RAID5(3+1)“). Beim Ausfall einer Platte ist mit verschlechterter Performance zu rechnen als bei RAID1/0.

Anmerkung
Die früher verwendeten RAID-S-Gruppen wurden nicht für hohe Schreiblasten empfohlen, da die Parity-Informationen auf nur einer physikalischen Platte lagen. Für RAID5 gilt diese Einschränkung nicht.

RAID6

Wie bei RAID5 wird der Datenstrom in Stripes unterteilt, jedoch werden nicht ein, sondern zwei Fehlerkorrekturwerte berechnet. Daten und Parity-Informationen werden so über die Platten verteilt, dass beide Parity-Informationen auf unterschiedlichen Platten liegen („dual rotating parity“). Bei RAID6 können bis zu zwei Platten ausfallen. Der Aufwand für die Resynchronisation, insbesondere bei zwei ausgefallenen Platten, ist jedoch erheblich höher als bei RAID5.

RAID6 wird für Symmetrix DMX-3 ab Microcode 5772, für DMX-4 und V-Max sowie für FibreCAT CX angeboten.

4.1.2.2 Replikationsfunktionen der Plattenspeichersysteme

Für Symmetrix- und FibreCAT CX-Plattenspeichersysteme stehen Funktionen zur lokalen Replikation innerhalb eines Plattenspeichersystems sowie Funktionen zur entfernten Replikation zwischen mehreren Plattenspeichersystemen zur Verfügung.

Das Softwareprodukt SHC-OSD ist die BS2000-Host-Komponente für Plattenspeichersysteme. Es stellt Informationsdienste und Kommandos zur Steuerung der Symmetrix-Funktionen SRDF und TimeFinder sowie der FibreCAT CX-Funktion Snapview zur Verfügung.

Eine ausführliche Beschreibung der Replikationsfunktionen ist im Handbuch „SHC-OSD“ [28] enthalten.

Symmetrix-Replikationsfunktion Symmetrix Remote Data Facility (SRDF™)

Die Produktfamilie SRDF (Symmetrix Remote Data Facility) der Firma EMC² Corporation unterstützt die Datenspiegelung eines lokalen Symmetrix-Systems (Local-Symmetrix) auf ein oder zwei entfernte Symmetrix-Systeme (Remote-Symmetrix).

Die Entfernung zwischen zwei Symmetrix-Systemen kann beim Kanal Typ S bis zu 60 km und beim Kanal Typ FC bis zu 10 km betragen. Bei Einsatz von Kanal-Erweiterungen können auch größere Entfernungen zwischen zwei Symmetrix-Systemen erreicht werden.

Bei Ausfall eines Symmetrix-Systems sind die aktuellen Daten (beim SRDF-Verarbeitungsmodus „synchrone Datenspiegelung“) stets auch im entfernten Symmetrix-System vorhanden. Das bedeutet nach dem Ausfall eines Symmetrix-Systems:

- die aktuellen Daten müssen nicht erst wieder eingespielt werden
- es muss nicht geprüft werden, ob die Sicherungen brauchbar oder konsistent sind
- es muss nicht auf einen älteren Datenbestand zurückgegangen werden

Das RAB (Raid Advisory Board) klassifiziert und zertifiziert RAID-Varianten unterschiedlicher Hersteller. Im aktuellen Schema des RAB erreichen Symmetrix-Systeme mit synchroner Datenspiegelung die höchste Sicherheitsstufe „DTDS+“
(Desaster Tolerant Disk System; „+“ steht für größere Entfernungen).

SRDF/A bietet (neben der synchronen Datenspiegelung mit SRDF) eine asynchrone Spiegelung mit plattenübergreifender Datenkonsistenz. Nach einem Ausfall ist mit SRDF/A ein konsistenter, zeitnaher Datenstand im entfernten Symmetrix-System verfügbar.

Mit SRDF bleiben die die für den Geschäftsbetrieb wichtigen Daten schnell verfügbar, auch wenn das lokale Symmetrix-System oder das gesamte lokale Data Center nach einen Ausfall oder wegen einer Katastrophe nicht verfügbar sind.

Leistungsverhalten mit SRDF

Wird eine Kopie der Daten in einem entfernten zweiten Symmetrix-System geführt, dann wird jeder Schreibzugriff zuerst in den lokalen Cache und anschließend in den „Remote-Cache“ eingetragen.

Das bedeutet, dass sich durch den Einsatz von SRDF die Hardware-Bedienzeit für Schreibzugriffe wenigstens verdoppelt. Zusätzlich ist eine erhöhte Protokollzeit zur Bearbeitung der Funktion zu berücksichtigen.

Üblicherweise beträgt die Write-Hit-Rate 100% (sofern genügend zeitliche „Erholungsphasen“ zum Sichern der Cache-Inhalte vorliegen), d.h. jedes Schreiben wird schnell durchgeführt. Bei kleinen Blöcken fällt die Verdoppelung der Hardware-Bedienzeit i.d.R. nicht ins Gewicht, bei großen Blöcken (z.B. Kopiervorgänge) ist die Verlängerung der Hardware-Bedienzeit deutlich.

Eine zusätzliche Verlängerung der Hardware-Bedienzeit kann eintreten, wenn die Leistungsfähigkeit der „Remote Data Links“ nicht ausreichend ist.

Bei SRDF/A fällt nur die „Protokollzeit“ an. Die Ein-/Ausgabe wird also wesentlich weniger verzögert (man beachte aber den „zeitlichen Datenversatz“, siehe Seite 63).

Details siehe bei „Auslastung der Ein-/Ausgabe-Peripherie“ auf Seite 312.

Symmetrix-Replikationsfunktion TimeFinder

Mit der Produktfamilie TimeFinder der Firma EMC^2 Corporation können (zusätzliche) Kopien der Anwendungsdaten innerhalb eines Symmetrix-Systems erstellt werden. Die kopierten Daten können separat adressiert und (nach einer Trennung von den Originaldaten) für sich bearbeitet werden, z.B. zur Sicherung oder für Testzwecke.

Die Produktfamilie TimeFinder besteht aus drei voneinander unabhängigen Produkten:

- TimeFinder/Snap: Unmittelbar verfügbarer Abzug („Snapshot“) der Daten
- TimeFinder/Clone: Unmittelbar verfügbare Kopie der Daten, wahlweise als „Snapshot“ oder als vollständige Kopie
- TimeFinder/Mirror: Vollständige Kopie der Daten auf Additional-Mirror-Units (synonym: Business Continuance Volume, BCV)

TimeFinder kann auch in Verbindung mit SRDF verwendet werden. Die Unit mit der Kopie der Daten kann an die SRDF-Source-Unit (im lokalen Symmetrix-System) oder an die SRDF-Target-Unit (in dem über SRDF gespiegelten entfernten Symmetrix-System) angehängt werden.

FibreCAT CX-Replikationsfunktionen

Für FibreCAT CX (CLARiiON CX)-Plattenspeichersysteme stehen Funktionen zur lokalen Replikation innerhalb eines FibreCAT CX-Systems sowie Funktionen zur entfernten Replikation zwischen mehreren FibreCAT CX-Systemen zur Verfügung.

FibreCAT MirrorView

Die Funktion MirrorView ermöglicht die synchrone oder asynchrone Datenspiegelung von ausgewählten logischen Datenvolumes eines FibreCAT CX-Systems auf ein bis vier weitere (entfernte) CX-Systeme. Pro LUN sind mehrere Spiegel möglich. Durch die Spiegelung bleibt für den Anwender die Datenverfügbarkeit auch bei kompletten Ausfällen des Data Centers und bei Katastrophen gewährleistet.

FibreCAT Mirrorview wird in BS2000/OSD im Rahmen von HIPLEX AF unterstützt. HIPLEX AF bietet eine automatische Desaster Recovery für SX-/SQ-Cluster (das sind Cluster mit SX-/SQ-Servern als Cluster-Elementen) mit FibreCAT CX-Plattensystemen. Die Ausfallerkennung und Steuerung zur Umschaltung mit Navisphere erfolgt durch den Monitor von HIPLEX AF.

FibreCAT SnapView

Die Funktion SnapView dient der lokalen Replikation innerhalb eines FibreCAT CX-Systems. SnapView wird in BS2000/OSD seit V8.0 und SHC-OSD V7.0 auf SX- und SQ-Servern unterstützt.

- SnapView/Snapshot: Unmittelbar verfügbarer Abzug („Snapshot“) der Daten (unterstützt ab Flare-Stand 26)
- SnapView/Clone: Vollständige Kopie der Daten (unterstützt ab Flare-Stand 26)

4.1.3 Konfigurierung in BS2000/OSD

Logische Volumes

Einzelne Platten sind auf den aktuellen Plattenspeichersystemen nur mehr bedingt sichtbar. BS2000/OSD sieht „logische Volumes“, die den LUNs (Logical Unit Numbers) zugeordnet sind. Die Zuordnung von LUNs zu physikalischen Platten ist für BS2000/OSD weitgehend verborgen. Die Plattenspeichersysteme sorgen, gesteuert über die RAID-Level, für eine performante Bedienung.

Es können auch „große“ logische Volumes verwendet werden. Das sind Volumes mit einer Größe von mehr als 32 Gbyte, siehe Handbuch „Dateien und Volumes größer 32 GB“ [2]. Für einen performanten Betrieb sind dann die Empfehlungen im Abschnitt „Hochleistungssysteme“ auf Seite 69 zu beachten.

Logische Volumes und physikalische Platten

Aus Sicht von BS2000/OSD sind logische Volumes voneinander unabhängige Einheiten, auf die parallel Ein-/Ausgaben eingeleitet werden können. Bei Einsatz der aktuellen, hochkapazitiven Platten befinden sich auf einem Plattenlaufwerk normalerweise mehrere logische Volumes.
Wenn Ein-/Ausgaben auf logische Volumes, die sich auf demselben Plattenlaufwerk befinden, parallel eingeleitet werden, dann tritt zwangsläufig eine Verlängerung der Hardware-Bedienzeit auf. Ob die Verlängerung der Hardware-Bedienzeit zu einer spürbaren Performance-Einbuße führt, ist abhängig von der Cache-Hit-Rate und der Auslastung des Plattenlaufwerks – möglicherweise auch durch Nutzer außerhalb von BS2000/OSD.

Bei physikalischen Platten, die gemeinsam von mehreren Programmen benutzt werden, liegt normalerweise keine zeitliche Gleichverteilung der Ein-/Ausgabe-Anforderungen vor. Bei höheren Gesamt-Auslastungen führt dies entsprechend den Gesetzen über Warteschlangenbildung zu untragbar hohen Wartezeiten vor den Platten, d.h. die Software-Bedienzeit für jede Ein-/Ausgabe ist wesentlich größer als die Hardware-Bedienzeit (siehe auch den Abschnitt „Ablauf einer Ein-/Ausgabe“ auf Seite 286). Zur Minimierung dieser Wartezeiten sollte die Auslastung gemeinsam benutzter Platten 30 % nicht überschreiten. Dieser Forderung liegt die Annahme zugrunde, dass die Wartezeit vor der Platte generell nicht höher als ein Drittel der Hardware-Bedienzeit sein sollte.

Anforderungen an die Konfigurierung des Plattenspeichersystems

Aus Sicht von BS2000/OSD kann die Auslegung der Plattenperipherie unter verschiedenen Gesichtspunkten erfolgen:

- hohe Kapazität (statischer Speicherplatz im Plattenspeichersystem, in GByte)
- hoher Durchsatz (in Mbyte/s)
- kurze Ein-/Ausgabezeiten (in ms pro Ein-/Ausgabe)

Da BS2000/OSD keine Kenntnis über die Zuordnung von logischen Volumes zu physikalischen Platten hat, müssen bei der Generierung des Symmetrix-Plattenspeichersystems gewisse Performance-Anforderungen berücksichtigt werden. Insbesondere sind das

- Größe der Volumes
- Anzahl der Ein-/Ausgabe-Pfade
- RAID-Level
- Art der Server-Last
  (OLTP-Betrieb, durchsatz-orientierter Batch-Betrieb -
  die Hauptanwendung muss berücksichtigt werden)
- Ein-/Ausgabelast des jeweiligen Volumes
  (Ein-/Ausgaben pro Sekunde oder allgemeine Aussage: niedrig / hoch -
  die Spitzenlast muss berücksichtigt werden)

Die konkrete Konfigurierung des Symmetrix-Plattenspeichersystems kann bzw. muss in vielen Fällen dem Service überlassen werden. Insbesondere muss vermieden werden, dass mehrere, hochbelastete logische Volumes auf dieselbe physikalische Platte gelegt werden. Bei Mischkonfigurationen mit anderen Systemen sollte auf die speziellen Eigenschaften des BS2000-Betriebs hingewiesen werden (z.B. sehr hohe und sehr gleichmäßige Last, die aber auch eine zuverlässige Performance der Peripherie voraussetzt).

Datenformat

Es wird empfohlen, das NK-Datenformat zu verwenden. Gegenüber dem K-Datenformat, bei dem auch die Schlüsselinformationen mitgeführt werden müssen, nutzt das NK-Datenformat die Plattenkapazität und den Cache-Speicher besser aus und erreicht damit kürzere Hardware-Bedienzeiten.

Messungen

Für Symmetrix-Systeme können Sie mit dem Softwareprodukt SHC-OSD ermitteln

- welche logischen Volumes auf einer Platte eingerichtet sind:
  ```
  /SHOW-SYMMETRIX-DEVICE-CONFIG UNIT=*BY-VOLUME(VOL=...),
                                CONFIGURATION=*PHYSICAL
  ```
- auf welcher oder welchen physikalischen Platte(n) ein BS2000-Volume liegt:
  ```
  /SHOW-SYMMETRIX-DEVICE-CONFIG UNIT=<mn>,INFORMATION=*PHYSICAL
  ```

Für FibreCAT CX-Systeme können Sie mit dem Softwareprodukt SHC-OSD ermitteln

- in welcher RAID-Gruppe sich ein BS2000-Volume befindet:
  ```
  /SHOW-STORAGE-DEVICE-CONFIG UNIT=<mn>,INFORMATION=*PHYSICAL
  ```
- welche weiteren Volumes sich in derselben RAID-Gruppe befinden:
  ```
  /SHOW-SYMMETRIX-DEVICE-CONFIG UNIT=<MN>,CONFIGURATION=*PHYSICAL
  ```

Wenn das Softwareprodukt SHC-OSD installiert ist, dann werden in der Reportgruppe `STORAGE-SYSTEM-SYMMETRIX` von openSM2 Messwerte über das Symmetrix-System erfasst, z.B. die Anzahl der Lese- und Schreibvorgänge sowie die Anzahl der Read-Hits und damit die Read-Hit-Rate. Auch für physikalische Geräte können Informationen, z.B. der Durchsatz, ermittelt werden. Weitere Informationen dazu finden Sie im Kapitel „Einsatz des Mess-Systems openSM2“ auf Seite 293.

Die Laufwerksauslastung ist mit BS2000-Mitteln nicht zugänglich und kann daher mit openSM2 nicht gemessen werden. Sie setzt sich aus der Summe der Ein-/Ausgabe-Lasten der jeweiligen logischen Volumes zusammen.

4.1.4 Hochleistungssysteme

Voraussetzung für den Betrieb von Hochleistungs-Plattenspeichersystemen ist der Server-Anschluss über Kanal Typ FC bzw. einen FC-Anschluss.

Ein erheblicher Leistungszuwachs kann zudem durch die Nutzung der BS2000-Funktion Parallel Access Volume (PAV) auf S-Servern bzw. der Funktion Remote System Call (RSC) auf SX- und SQ-Servern (standardmäßig verwendet) erreicht werden. Um das Potenzial von PAV nutzen zu können, müssen geeignete RAID-Levels gewählt werden.

Anschlussart Fibre Channel

Voraussetzung für eine performante Bedienung jeder Peripherie ist ein Server-Anschluss über Kanal Typ FC bzw. einen FC-Anschluss.

Mit Kanälen Typ S kann die Leistungsfähigkeit der aktuellen Peripheriegeräte nicht ausgenutzt werden.

Parallel Access Volume (PAV)

Beim einfachen Plattenzugriff (Standard) ist auf S-Servern zur gleichen Zeit nur ein Ein-/Ausgabeauftrag auf ein logisches Volume in Bearbeitung. Weitere Aufträge werden in BS2000/OSD serialisiert.

Alternativ dazu wird mit der BS2000-Funktion PAV ein paralleler Plattenzugriff an S-Servern unterstützt. Mit PAV werden mehrere Geräteadressen (Alias-Geräte) einem logischen Volume (Basis-Gerät) zugeordnet. Damit können mehrere Ein-/Ausgabeaufträge parallel auf ein Volume eingeleitet werden. Im Plattenspeichersystem können dann mehrere Cache-Hits gleichzeitig bedient werden, während parallel dazu bei einem Cache-Miss ein physikalischer Plattenzugriff durchgeführt wird. Nähere Informationen zu PAV finden Sie im Handbuch „Systembetreuung“ [11].

Alias-Geräte am Kanal Typ FC müssen in BS2000/OSD generiert werden. In der Steuerung ist kein Eingriff erforderlich.

„Statisches PAV“ verlangt eine vorausschauende Planung auf die zukünftige Geräteauslastung. Den stark ausgelasteten Geräten muss im Voraus die richtige Anzahl von Alias-Geräten zugewiesen werden.

Beim „Dynamischen PAV“ für Kanal Typ FC weist das Dienstprogramm IORM automatisch den stark belasteten Volumes Alias-Geräte (DPAV-Geräte) zu, die am meisten davon profitieren. Die Generierung von Alias-Geräten entfällt. Ein-/Ausgabeengpässe werden dadurch entschärft.

Remote System Call (RSC)

Für SX- und SQ-Server gibt es mit der Funktion Remote System Call (RSC) für Platten eine dem PAV ähnliche Funktion. Bis zu sechs Ein-/Ausgaben sind gleichzeitig auf ein Volume bzw. Gerät möglich. Die Serialisierung erfolgt im Plattenspeichersystem. RSC wird standardmäßig genutzt, der Anwender muss **keine** besondere Konfigurationseinstellung für die Nutzung von RSC und für die Parallelisierung von Ein-/Ausgaben treffen.

PAV und RAID-Level

Durch den Einsatz von PAV bzw. RSC können bessere Ein-/Ausgabezeiten und höherer Durchsatz erwartet werden. Über die tatsächliche Performance-Verbesserung entscheidet der RAID-Level (siehe Abschnitt „PAV und RAID-Level bei OLTP-Betrieb“ auf Seite 77):

- Bessere Ein-/Ausgabezeiten werden bei allen RAID-Levels erreicht.
- Ein besserer Durchsatz wird nur erreicht, wenn der verwendete RAID-Level die Parallelität von PAV bzw. RSC auch nutzen kann. Dies ist vor allem bei RAID-Levels mit „data striping“ möglich, also RAID1/0, RAID5 und RAID6. Für RAID1 gilt dies nur eingeschränkt.

Für einen performanten Einsatz wird RAID1/0 oder, falls die Plattenkapazität sehr wichtig ist und bei nicht zu hoher Random-Schreiblast, RAID5 oder RAID6 empfohlen, auf S-Servern zusammen mit DPAV.

Empfehlungen

Für einen performanten Betrieb von Plattenspeichersystemen sollten folgende Empfehlungen beachtet werden:

- Anschluss nur über Kanal Typ FC bzw. einen FC-Anschluss
- Möglichst neue Plattenspeichersysteme verwenden:
  - mit neuestem Firmware-Stand
  - mit ausreichend Cache-Speicher (muss so groß gewählt werden, dass bei OLTP-Betrieb eine Read-Hit-Rate von 60 - 80% erreicht wird)
  - mit schnellen Platten (mindestens 10.000 rpm)
  - große Platten können verwendet werden
- RAID-Level RAID1/0 oder, bei nicht zu hoher Random-Schreiblast, RAID5 oder RAID6
  - bei S-Servern Einsatz von PAV, besser DPAV
  - dann können auch „große“ Volumes (mit mehr als 32 Gbyte) verwendet werden
- Blockgröße 160 KB pro Ein-/Ausgabe bei durchsatz-orientierten Anwendungen, falls möglich
- allgemeine Erhöhung der Parallelität
  (im Betriebssystem, in Dienstprogrammen und Anwendungen)

4.1.5 Lasttypen

Anwendungen

Für die Auslegung der Plattenperipherie sind sowohl das Lastprofil als auch die zeitlichen Anforderungen der Anwendung maßgebend. In der Praxis treten im Wesentlichen zwei Lasttypen auf, die sich folgendermaßen charakterisieren lassen:

	OLTP-Betrieb (Datenbank-Anwendungen)	**Anwendungen mit großer Blockgröße (Batch-Verarbeitung, Datensicherung)**
typische Blockgröße pro Ein-/Ausgabe	„klein“: 2 KB oder 4 KB	„groß“: 16 KB oder größer
Belastungsart	Ein-/Ausgaberate (Ein-/Ausgaben/s)	Durchsatz (Mbyte/s)
typische Ein-/Ausgabe-Operationen	Random-Zugriff	Random-Zugriff sequenzieller Zugriff

Anwendungen in BS2000/OSD können Blockgrößen bis zu 160 KB pro Ein-/Ausgabe verwenden. Der Durchsatz kann damit erheblich gesteigert werden.

Anwendungen können die Performanceverbesserungen mit PAV bzw. RSC und entsprechenden RAID-Levels nur dann realisieren, wenn sie Anforderungen parallel und ohne wesentliche gegenseitige Beeinträchtigung bearbeiten können. Dies ist beim OLTP-Betrieb in der Regel der Fall. Auch die aktuellen Versionen der Datensicherungsprodukte HSMS/ARCHIVE und FDDRL sind dafür vorbereitet. Im Batch-Betrieb können die Performanceverbesserungen nur bei parallelen Ein-/Ausgaben realisiert werden.

Je nach Anwendungsart stehen unterschiedliche Performance-Ziele im Vordergrund. Bei der Datensicherung und im Batch-Betrieb wird ein hoher Durchsatz angestrebt, beim OLTP-Betrieb werden gute Antwortzeiten erwartet. Einen wichtigen Anteil an Durchsatz bzw. Verweilzeit und Antwortzeit bzw. Transaktionszeit haben die Ein-/Ausgaben (siehe Abschnitt „Kenngrößen für die Beschreibung der Leistung eines IT-Systems“ auf Seite 17). Im Folgenden werden die Ein-/Ausgabezeiten aus Sicht des Anwenders („Software-Bedienzeit“) und die reine Zeit für die Hardware-Bedienung („Hardware-Bedienzeit“) betrachtet (siehe Abschnitt „Ablauf einer Ein-/Ausgabe“ auf Seite 286). Die „Software-Bedienzeit“ setzt sich im Wesentlichen zusammen aus der Hardware-Bedienzeit und den Wartezeiten bis zur Einleitung der Ein-/Ausgabe.

Standardisierte Lasttypen

Für die Messungen in den folgenden Abschnitten wurden standardisierte Lastfälle verwendet:

- „Random25“

  Random-Zugriffe mit einem Anteil von 25% Schreiben und 75% Lesen.
  Dieser Fall ist bei kurzen Blöcken einem OLTP-Betrieb nachempfunden.

- „Sequential Write“, „Sequential Read“

  Sequenzielles Schreiben bzw. Lesen.
  Dies ist bei großen Blöcken einer Batch-Verarbeitung nachempfunden.

4.2 Plattenspeichersysteme an S-Servern

4.2.1 Symmetrix DMX und V-Max am Kanal Typ FC

Dieser Abschnitt enthält Messergebnisse und Folgerungen für die Performance der Plattenspeichersysteme Symmetrix DMX-3 und V-Max bei Anschluss an S-Server über Kanäle Typ FC.

Der Durchsatz eines Plattenspeichersystems Symmetrix DMX-4 oder V-Max ist vergleichbar mit dem Durchsatz von DMX-3. Auch die Hardware-Bedienzeiten bei Read-Hit sind vergleichbar. Die Hardware-Bedienzeiten bei Read-Miss sind bei DMX-4 und V-Max kürzer als bei DMX-3.

4.2.1.1 Durchsatz mit einem Task (DMX-3)

Die folgenden beiden Tabellen zeigen den erzielten Durchsatz (die Ein-/Ausgaberate in Ein-/Ausgaben pro Sekunde (IO/s) und den Durchsatz in Mbyte/s), den ein Anwendertask bei Plattenzugriffen zum Plattenspeichersystems Symmetrix DMX-3 (Platten der Größe 146 GB mit 15.000 rpm) über Kanal Typ FC erreichen kann.

Der Durchsatz wurde für die standardisierten Lasttypen bei verschiedenen Blockgrößen und einer Read-Hit-Rate von 100% für den Plattentyp D3435 bei Datenformat NK2 gemessen:

Eine Task: Ein-/Ausgaben/s	**Blockgröße (KB)**					
	2	**4**	**8**	**16**	**32**	**160**
„Random25“	3.400	3.200	2.500	2.200	1.550	430
„Sequential read“	3.700	3.500	3.000	2.300	1.600	450
„Sequential write“	3.000	2.800	2.500	2.100	1.500	400

Eine Task: Mbyte/s	**Blockgröße (KB)**					
	2	**4**	**8**	**16**	**32**	**160**
„Random25“	7,1	13	21	37	51	70
„Sequential read“	7,7	14	25	38	53	74
„Sequential write“	6,2	12	21	34	50	67

4.2.1.2 Durchsatz mit bis zu vier Kanälen Typ FC (V-Max)

Die folgenden beiden Tabellen zeigen den erzielten Durchsatz (die Ein-/Ausgaberate in Ein-/Ausgaben pro Sekunde (IO/s) und den Durchsatz in Mbyte/s) bei Plattenzugriffen zum Plattenspeichersystem Symmetrix V-Max bei bis zu vier Kanälen Typ FC.

Der Durchsatz wurde für den Lasttyp „Random25“ bei verschiedenen Blockgrößen und einer Read-Hit-Rate von 100% für den Plattentyp D3435 bei Datenformat NK2 gemessen:

„Random25“: Ein-/Ausgaben/s	**Blockgröße (KB)**					
	2	**4**	**8**	**16**	**32**	**160**
1 Kanal Typ FC	8.800	8.800	8.200	5.700	3.400	700
2 Kanäle Typ FC	17.000	17.000	16.000	11.000	6.800	1.400
4 Kanäle Typ FC	34.000	33.000	29.000	21.000	12.000	2.600

„Random25“: Mbyte/s	**Blockgröße (KB)**					
	2	**4**	**8**	**16**	**32**	**160**
1 Kanal Typ FC	18	36	67	93	110	115
2 Kanäle Typ FC	34	69	130	180	220	225
4 Kanäle Typ FC	69	135	235	345	400	425

Fibre Channel Anschlüsse skalieren sehr gut. Das heißt, mit n Kanälen Typ FC kann annähernd der n-fache Durchsatz erreicht werden. Voraussetzung dafür ist eine ausreichende Leistung der BS2000-CPUs und der Peripherie.

4.2.1.3 Hardware-Bedienzeiten (DMX-3)

Hardware-Bedienzeiten beim Lesen

Folgende Tabelle zeigt die Ein-/Ausgabezeiten (Hardware-Bedienzeiten) für Read-Hit und Read-Miss, wie sie in üblichen Konfigurationen und bei üblichem Lastaufkommen erreicht werden. Die Zeiten für den Read-Miss werden abhängig vom RAID-Level dargestellt.

Die Hardware-Bedienzeiten sind neben der Ein-/Ausgaberate auch abhängig vom Ausbau des Plattenspeichersystems. Bei den Messungen wurde ein Plattenspeichersystem Symmetrix DMX-3, angeschlossen über 4 Kanäle Typ FC, mit 16 Volumes auf Platten vom Typ D3435 mit Datenformat NK2 und mit geringer gegenseitiger Beeinflussung (durch wenige logische Volumes auf einem physikalischen Gerät) verwendet. Bei kleinen Konfigurationen können die Zeiten etwas günstiger sein. Bei sehr großen Konfigurationen können die Zeiten schlechter sein.

Ein-/Ausgabezeit Lesen (ms)	**Blockgröße (KB)**					
	2	**4**	**8**	**16**	**32**	**160**
Read-Hit	0,24	0,28	0,36	0,52	0,84	3,4
Read-Miss RAID1	4,8	4,9	5,0	5,3	6,0	11
Read-Miss RAID1/0	4,8	4,9	5,0	5,3	6,0	11
Read-Miss RAID5	5,3	5,4	5,6	6,0	6,8	13

Hardware-Bedienzeiten bei OLTP-Betrieb

Folgende Tabellen zeigen die Ein-/Ausgabezeiten (Hardware-Bedienzeiten) bei unterschiedlichen RAID-Leveln und Read-Hit-Raten, wie sie für einen OLTP-Betrieb (Lasttyp „Random25“) bei üblichen Konfigurationen und üblichem Lastaufkommen erreicht werden. Bei den Schreibaufträgen wird von einem ausreichend großen Cache des Plattenspeichersystems ausgegangen, d.h. der Schreibauftrag ist nach der Übertragung in den Cache abgeschlossen. Der Transfer auf die physikalischen Platten erfolgt asynchron.

RAID1(1+1), RAID1/0(4+4)

Ein-/Ausgabezeit „Random25“ (ms)	Blockgröße (KB)					
	2	**4**	**8**	**16**	**32**	**160**
Read-Hit 100%	0,27	0,31	0,39	0,55	0,87	3,4
Read-Hit 80%	0,95	1,0	1,1	1,3	1,6	4,6
Read-Hit 60%	1,6	1,7	1,8	2,0	2,4	5,7

RAID5(3+1)

Ein-/Ausgabezeit „Random25“ (ms)	Blockgröße (KB)					
	2	**4**	**8**	**16**	**32**	**160**
Read-Hit 100%	0,27	0,31	0,39	0,55	0,87	3,4
Read-Hit 80%	1,0	1,1	1,2	1,4	1,8	4,9
Read-Hit 60%	1,8	1,8	2,0	2,2	2,6	6,4

Die Ein-/Ausgabezeiten gelten für „normale“ Last, d.h. einer Ein-/Ausgaberate, bei der das logische Volume nicht überlastet ist, wobei RAID1/0(4+4) die höchste und RAID1(1+1) die niedrigste Last verträgt.

Die Größenordnung der normalen Last und der Grenze zur Hochlast / Überlast sind im folgenden Abschnitt „PAV und RAID-Level bei OLTP-Betrieb“ und im Abschnitt „Hochlast, Überlast“ auf Seite 89 beschrieben.

4.2.1.4 PAV und RAID-Level bei OLTP-Betrieb

Für Hochleistungssysteme wird neben einem Anschluss über Kanal Typ FC für S-Server der Einsatz von PAV/DPAV (Dynamic Parallel Access Volume) zusammen mit einem geeigneten RAID-Level empfohlen. Dieser Abschnitt zeigt, dass sich die Ein-/Ausgabezeiten und der Durchsatz (Ein-/Ausgaberaten) durch den Einsatz von PAV verbessern lassen.

Die folgenden Diagramme zeigen die Ein-/Ausgabezeiten (Software-Zeiten = Summe aus Hardware-Bedienzeiten und Software-Wartezeiten) bei verschiedenen RAID-Levels und bei einer für einen OLTP-Betrieb typischen Last:

- kurze Blöcke (2 KBytes)
- standardisierter Lasttyp „Random25“
- Read-Hit-Rate 80%

Bei den Messungen wurde folgende Konfiguration verwendet:

- Plattenspeichersystem Symmetrix DMX-3 (Platten der Größe 146 GB mit 15.000 rpm), angeschlossen über 4 Kanäle Typ FC
- Platten vom Typ D3435 mit Datenformat NK2
- Jeweils 8 Volumes auf unabhängigen physikalischen Platten.
  Pro Volume waren 8 Tasks aktiv.

Bei steigender Last (Ein-/Ausgaberate) werden die Ein-/Ausgabezeiten (Hardware + Software) bei verschiedenen RAID-Leveln verglichen. Für jeden RAID-Level wurden Messungen mit unterschiedlich vielen Alias-Geräten durchgeführt.

Die folgenden Messungen wurden mit dem Symmetrix-Plattenspeichersystem DMX-3 durchgeführt. Die Ergebnisse zu PAV gelten analog auch für Symmetrix DMX-4 und V-Max.

RAID1 (1+1 Platten)

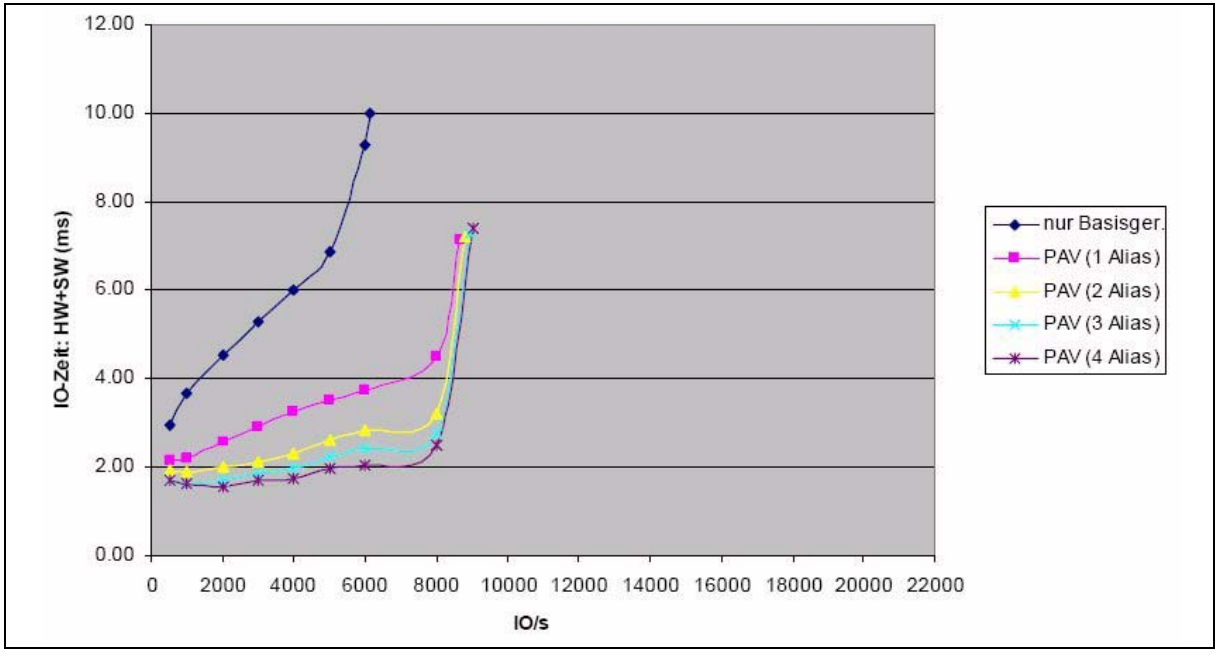

RAID5 (3+1 Platten)

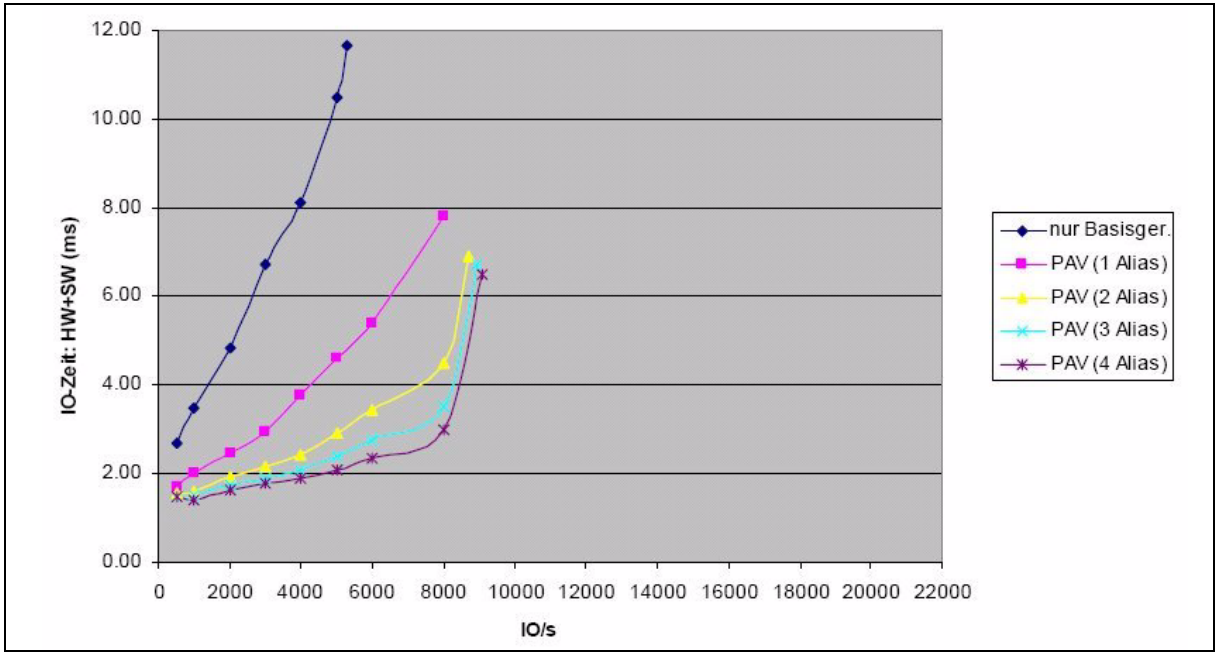

RAID1/0 (4+4 Platten)

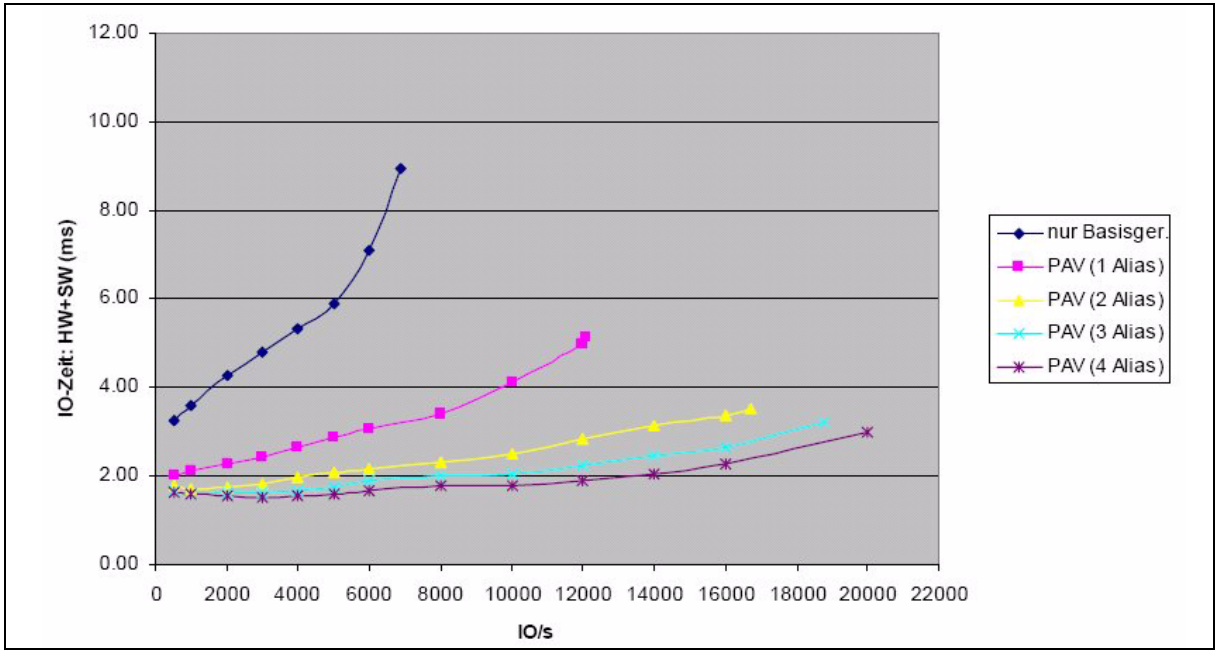

Mit PAV und bei RAID1/0 kann die Parallelität der Ein-/Ausgabelast effektiv genutzt werden.

Mit PAV ergeben sich erhebliche Verbesserungen. Schon mit einem Aliasgerät sinken die Ein-/Ausgabezeiten und steigen die Ein-/Ausgaberaten deutlich. Eine weitere Verbesserung ergibt sich mit 2 Aliasgeräten. Weitere Aliasgeräte bringen nur noch geringe Verbesserungen.
Beim Einsatz von DPAV sorgt das Dienstprogramm IORM für die Zuordnung einer adäquaten Anzahl von Aliasgeräten.

Bei gleicher Ein-/Ausgaberate ergeben sich mit PAV bei allen RAID-Levels deutlich bessere Ein-/Ausgabezeiten (Hardware- und Softwarezeiten).

Bei den RAID-Levels RAID1 und RAID5 werden mit PAV deutlich bessere Ein-/Ausgaberaten erreicht. Wegen des höheren Aufwandes beim Schreiben (Berechnen und Schreiben der Parity-Informationen) liegt die Ein-/Ausgaberate von RAID5 trotz des „data striping“ über mehrere Platten in der Größenordnung von RAID1. Die Ein-/Ausgabezeiten und Ein-/Ausgaberaten von RAID6 liegen in der Größenordnung von RAID5.

Eine wesentlich höhere Ein-/Ausgaberate erreicht RAID1/0. Hier spielt neben dem „data striping“ auch die größere Anzahl Platten eine Rolle.

Die für RAID1/0 in dieser Konfiguration mit akzeptablen Ein-/Ausgabezeiten erreichte Ein-/Ausgaberate liegt bei über 20.000 Ein-/Ausgaben pro Sekunde.

RAID6 (6+2 Platten)

Die Leistung von RAID6 (6+2 Platten) für S-Server mit Plattenspeichersystem DMX-3 wird im Vergleich zu RAID5 (3+1) und RAID1/0 (4+4) bewertet. Nicht betrachtet werden Kapazitäts- und Sicherheitsaspekte. Betrachtet wird das Verhalten mit PAV mit bis zu 4 Alias-Geräten.

Lesen

- Ohne PAV werden bei allen drei RAID-Leveln beim „Sequential read“ gute Durchsätze von etwa 70 Mbyte/s erreicht.
- Mit PAV wird bei mehreren Alias-Geräten ein ausgezeichneter Durchsatz auf einem logischen Volume erreicht. Er beträgt bei mehreren Tasks für alle drei RAID-Level 250 Mbyte/s.

Schreiben

- Ohne PAV ist beim „Sequential write“ der Durchsatz in allen RAID-Leveln etwa 60 Mbyte/s. Beim „Random write“ sinkt der Durchsatz bei RAID5 und RAID6 aber auf 20-30 Mbyte/s, also deutlich unter den RAID1/0-Wert (60 Mbyte/s).
- Auch beim Schreiben mit PAV und mehreren Alias-Geräten ist RAID1/0 performanter als RAID5 oder RAID6, bei denen die Parity-Informationen zusätzlich berechnet und geschrieben werden müssen. Mit RAID1/0 wird beim „Sequential write“ auf ein Volume ein hervorragender Durchsatz von mehr als 200 Mbyte/s erreicht.
  Bei RAID5 und RAID6 wird ein Durchsatz von etwa 100 Mbyte/s erreicht.
  Beim „Random write“ sind die Vorteile von RAID1/0 noch ausgeprägter (Faktor 3-5).
- Der Durchsatz von RAID5 und RAID6 liegt in der gleichen Größenordnung.

Bewertung:

- Mit PAV kann der Durchsatz auf S-Servern erheblich gesteigert werden, auch mit 2 oder 3 Alias-Geräten. (D)PAV wird uneingeschränkt empfohlen.
- TP-Betrieb:
  Beim Schreiben in einem normalen TP-Betrieb wird davon ausgegangen, dass im Cache des Plattenspeichersystems genügend Platz ist, dass also kein „Delayed Fast Write“ nötig ist. Alle drei RAID-Level werden empfohlen.
- Datensicherung:
  Hier wird von den Platten gelesen. Alle drei RAID-Level werden empfohlen.
- Datenrekonstruktion:
  Hier wird auf die Platten geschrieben. Dabei ist RAID1/0 vorteilhaft. Die Begrenzungen auf der Band-Seite sind zu beachten (siehe Seite 129).

4.2.2 Symmetrix 8000 am Kanal Typ S

Dieser Abschnitt enthält Messergebnisse über und Folgerungen für die Performance des Plattenspeichersystems Symmetrix 8000 bei Anschluss an S-Server über Kanäle Typ S.

4.2.2.1 RAID1

Abhängig von der Blockgröße ergeben sich für den Read-Hit ungefähr die nachfolgenden Hardware-Bedienzeiten (Kanal Typ S: CKD-Format mit K-Datenformat). Die Werte gelten auch für den Write-Hit, solange die Cache-Größe für die Aufnahme der Schreibdaten ausreicht bzw. keine vorherige Auslagerung auf Platte erforderlich ist.

	Hardware-Bedienzeit (ms)	
Blockgröße	**Read-Hit**	**Read-Miss**
2 KB	0,5 - 0,8	8-10
4 KB	0,8 - 1,0	8-10
8 KB	1,3 - 1,5	8-10
16 KB	2,3 - 2,5	9-11
32 KB	4,3 - 4,5	10-12

Die folgenden Tabellen zeigen das Verhalten der Hardware-Bedienzeit für verschiedene Blockgrößen bei steigendem Ein-/Ausgabe-Durchsatz beim Plattenspeichersystem Symmetrix 8530 über Kanal Typ S.

Der Ein-/Ausgabe-Durchsatz wird unter optimalen Bedingungen (keine konkurrierenden Zugriffe pro Plattenlaufwerk) in folgenden Kombinationen dargestellt:

- CKD-Plattenformat und K-Datenformat
- CKD-Plattenformat und NK4-Datenformat
- FBA-Plattenformat und K-Datenformat
- FBA-Plattenformat und NK2-Datenformat

Als Lasttyp werden Random-Zugriffe mit 25% Schreibanteil bei verschiedenen Blockgrößen verwendet.

Die Hardware-Bedienzeit bezieht sich auf Read-Hit-Raten von 60%, 80% und 100%, die durch entsprechende Variation der Dateigrößen fest vorgegeben sind.

RAID1: CKD-Plattenformat mit K-Datenformat (4 Kanäle Typ S)

Plattenspeichersystem Symmetrix 8530 (RAID1)	Ein-/Ausgaben pro Sekunde	Hardware-Bedienzeit (ms) bei Read-Hit-Rate von		
		60%	80%	100%
Blockgröße = 2 KB	2.000	2,6	1,6	0,5
	4.000	3,1	1,8	0,5
	6.000	3,8	2,0	0,5
Blockgröße = 4 KB	2.000	2,9	1,8	0,8
	4.000	3,4	2,0	0,8
	5.000	4,0	2,2	0,8
Blockgröße = 8 KB	2.000	3,5	2,2	1,3
	3.000	3,8	2,4	1,3
	4.000	4,6	2,6	1,3
Blockgröße = 16 KB	1.000	4,4	3,2	2,3
	2.000	4,6	3,3	2,3
	3.000	5,9	3,6	2,3

RAID1: CKD-Plattenformat mit NK4-Datenformat (4 Kanäle Typ S)

Plattenspeichersystem Symmetrix 8530 (RAID1)	Ein-/Ausgaben pro Sekunde	Hardware-Bedienzeit (ms) bei Read-Hit-Rate von		
		60%	80%	100%
Blockgröße = 4 KB	2.000	2,8	1,7	0,6
	4.000	3,2	1,9	0,6
	5.000	3,6	2,0	0,6
Blockgröße = 8 KB	2.000	2,9	1,9	0,9
	3.000	3,0	1,9	0,9
	4.000	3,4	2,0	0,9
Blockgröße = 16 KB	1.000	3,6	2,4	1,5
	2.000	3,8	2,4	1,5
	3.000	4,9	2,5	1,5

Bei CKD-Plattenformatierung führt das NK4-Datenformat gegenüber dem K-Datenformat zu einer besseren Nutzung der Plattenkapazität und des Cache-Speichers.
Auch bei gleicher Read-Hit-Rate ist beim NK4-Datenformat die Hardware-Bedienzeit kürzer als beim K-Datenformat.

RAID1: FBA-Plattenformat mit K-Datenformat (4 Kanäle Typ S)

Plattenspeichersystem Symmetrix 8530 (RAID1)	Ein-/Ausgaben pro Sekunde	Hardware-Bedienzeit (ms) bei Read-Hit-Rate von		
		60%	80%	100%
Blockgröße = 2 KB	2.000	2,8	1,8	0,7
	4.000	3,0	1,8	0,7
	6.000	3,8	2,0	0,7
Blockgröße = 4 KB	2.000	3,0	2,0	1,0
	4.000	3,4	2,1	1,0
	5.000	4,0	2,2	1,0
Blockgröße = 8 KB	2.000	3,6	2,4	1,5
	3.000	3,8	2,5	1,5
	4.000	4,6	2,6	1,5
Blockgröße = 16 KB	1.000	4,5	3,4	2,5
	2.000	4,7	3,5	2,5
	3.000	5,9	3,6	2,5

Die FBA-Plattenformatierung mit K-Datenformat zeigt – bei besserer Nutzung der Plattenkapazität – gegenüber der CKD-Plattenformatierung mit K-Datenformat geringfügig höhere Hardware-Bedienzeiten (0,2 ms).

RAID1: FBA-Plattenformat mit NK2-Datenformat (4 Kanäle Typ S)

Plattenspeichersystem Symmetrix 8530 (RAID1)	Ein-/Ausgaben pro Sekunde	Hardware-Bedienzeit (ms) bei Read-Hit-Rate von		
		60%	80%	100%
Blockgröße = 2 KB	2.000	2,7	1,6	0,6
	4.000	3,0	1,7	0,6
	6.000	3,6	1,9	0,6
Blockgröße = 4 KB	2.000	2,8	1,7	0,8
	4.000	3,2	1,9	0,8
	5.000	3,6	2,0	0,8
Blockgröße = 8 KB	2.000	2,9	1,9	1,1
	3.000	3,0	2,0	1,1
	4.000	3,3	2,1	1,1
Blockgröße = 16 KB	1.000	3,6	2,4	1,7
	2.000	3,8	2,4	1,7
	3.000	4,8	2,5	1,7

Bei FBA-Plattenformatierung führt das NK2-Datenformat gegenüber dem K-Datenformat zu einer besseren Nutzung der Plattenkapazität und des Cache-Speichers.
Auch bei gleicher Read-Hit-Rate ist beim NK2-Datenformat die Hardware-Bedienzeit kürzer als beim K-Datenformat.

4.2.2.2 RAID5

Die folgende Tabelle zeigt das Verhalten der Hardware-Bedienzeit für verschiedene Blockgrößen bei Random-Zugriffen mit 25% Schreibanteil und steigendem Ein-/Ausgabe-Durchsatz. Das Symmetrix-System 8530 ist über 4 Kanäle Typ S angeschlossen.

RAID5(3+1): CKD-Plattenformat mit K-Datenformat, Kanal Typ S

Plattenspeichersystem Symmetrix 8530 (RAID5)	Ein-/Ausgaben pro Sekunde	Hardware-Bedienzeit (ms) bei Read-Hit-Rate von		
		60%	80%	100%
Blockgröße = 2 KB	2.000	3,5	2,1	0,5
	4.000	4,0	2,3	0,5
	6.000	4,9	2,7	0,5
Blockgröße = 4 KB	2.000	3,8	2,3	0,8
	4.000	4,4	2,5	0,8
	5.000	5,1	2,8	0,8
Blockgröße = 8 KB	2.000	4,4	2,8	1,3
	3.000	4,9	2,9	1,3
	4.000	5,7	3,3	1,3
Blockgröße = 16 KB	1.000	5,5	3,8	2,3
	2.000	5,8	4,0	2,3
	3.000	7,1	4,3	2,3

4.3 Plattenspeichersysteme an SX- und SQ-Servern

Die Ein-/Ausgabe auf FC-Peripherie erfolgt über I/O-Prozessoren und die PCI-(FC-)Controller des SX- oder SQ-Servers.

4.3.1 FibreCAT CX

Dieser Abschnitt enthält Messergebnisse und Folgerungen für die Performance des Plattenspeichersystems FibreCAT CX3-20 (Platten der Größe 146 GB mit 15.000 rpm) beim FC-Anschluss an SX- oder SQ-Server.

Der Durchsatz eines Plattenspeichersystems FibreCAT CX4 ist vergleichbar mit dem Durchsatz von FibreCAT CX3. Auch die Hardware-Bedienzeiten bei Read-Hit und Read-Miss sind vergleichbar.

4.3.1.1 Durchsatz mit einem Task

Folgende Tabellen zeigen den erzielten Durchsatz (die Ein-/Ausgaberate in Ein-/Ausgaben pro Sekunde (IO/s) und den Durchsatz in Mbyte/s), den ein Anwendertask bei Plattenzugriffen zum Plattenspeichersystem FibreCAT CX3-20 über FC-Anschluss erreichen kann.

Der Durchsatz wurde für die standardisierten Lasttypen bei verschiedenen Blockgrößen und einer Read-Hit-Rate von 100% für den Plattentyp D3435 bei Datenformat NK2 gemessen:

Eine Task: Ein-/Ausgaben/s	**Blockgröße (KB)**					
	2	**4**	**8**	**16**	**32**	**160**
„Random25“	3.000	2.800	2.400	1.900	1.350	420
„Sequential read“	3.500	3.300	2.800	2.100	1.500	440
„Sequential write“	2.100	2.000	1.750	1.400	1.000	350

Eine Task: Durchsatz [Mbyte/s]	**Blockgröße (KB)**					
	2	**4**	**8**	**16**	**32**	**160**
„Random25“	6,2	11	20	31	44	69
„Sequential read“	7,3	13	23	35	49	72
„Sequential write“	4,4	8,3	14	23	34	57

Aussagen zum Durchsatz von IO-Prozessoren befinden sich im Abschnitt „Ein-/Ausgabe“ auf Seite 40.

4.3.1.2 Hardware-Bedienzeiten

Hardware-Bedienzeiten beim Lesen

Folgende Tabelle zeigt die Ein-/Ausgabezeiten (Hardware-Bedienzeiten) für Read-Hit und Read-Miss, wie sie in üblichen Konfigurationen und bei üblichem Lastaufkommen erreicht werden. Die Zeiten für den Read-Miss werden abhängig vom RAID-Level dargestellt.

Die Hardware-Bedienzeiten sind neben der Ein-/Ausgaberate auch abhängig vom Ausbau des Plattenspeichersystems. Bei den Messungen wurde ein Plattenspeichersystem FibreCAT CX3-20 (Platten der Größe 146 GB mit 15.000 rpm), angeschlossen über 2 FC-Anschlüsse, mit 4 Volumes auf Platten vom Typ D3435 mit Datenformat NK2 und mit geringer gegenseitiger Beeinflussung verwendet. Bei kleinen Konfigurationen können die Zeiten etwas günstiger sein. Bei sehr großen Konfigurationen können die Zeiten schlechter sein.

IO-Zeiten (Hardware-Bedienzeiten) für Read-Hit und Read-Miss

Ein-/Ausgabezeit Lesen (ms)	Blockgröße (KB)					
	2	4	8	16	32	160
Read-Hit	0,19	0,23	0,31	0,47	0,79	3,3
Read-Miss RAID1	7,3	7,4	7,7	8,3	9,4	18
Read-Miss RAID1/0	7,3	7,4	7,7	8,3	9,4	18
Read-Miss RAID5	8,3	8,5	8,9	9,6	11	23

Hardware-Bedienzeiten bei OLTP-Betrieb

Folgende Tabellen zeigen die Ein-/Ausgabezeiten (Hardware-Bedienzeiten) bei unterschiedlichen RAID-Leveln und Read-Hit-Raten, wie sie für einen OLTP-Betrieb (Lasttyp „Random25“) bei üblichen Konfigurationen des Plattenspeichersystems FibreCAT CX3-20 und üblichem Lastaufkommen erreicht werden.

RAID1(1+1) und RAID1/0(4+4)

Ein-/Ausgabezeit „Random25“ (ms)	Blockgröße (KB)					
	2	**4**	**8**	**16**	**32**	**160**
Read-Hit 100%	0,22	0,26	0,34	0,50	0,82	3,4
Read-Hit 80%	1,3	1,3	1,4	1,7	2,1	5,6
Read-Hit 60%	2,3	2,4	2,6	2,8	3,4	7,9

RAID5(3+1)

Ein-/Ausgabezeit „Random25“ (ms)	Blockgröße (KB)					
	2	**4**	**8**	**16**	**32**	**160**
Read-Hit 100%	0,22	0,26	0,34	0,50	0,82	3,4
Read-Hit 80%	1,4	1,5	1,6	1,9	2,3	6,3
Read-Hit 60%	2,7	2,7	2,9	3,2	3,9	9,1

4.3.1.3 Hochlast, Überlast

Dringende Empfehlung
Volumes mit hoher Last sollen auf unterschiedlichen physikalischen Platten liegen. Andernfalls kann es (unabhängig vom verwendeten Plattenspeichersystem) zu erheblichen Performance-Problemen kommen.

Dieser Abschnitt untersucht das Verhalten eines Plattenspeichersystemens mit mehreren, hoch belasteten logischen Volumes, die auf der gleichen physikalischen Platte eingerichtet sind. Die Ergebnisse sind unabhängig vom verwendeten Plattenspeichersystem, siehe auch die Anmerkungen im Abschnitt „Logische Volumes und physikalische Platten“ auf Seite 66.

Maximale Ein-/Ausgaberaten bei OLTP-Betrieb

Die Ein-/Ausgabezeiten (Hardware-Bedienzeiten) der Tabellen im vorangehenden Abschnitt gelten für „normale“ Last, d.h. weder Kanäle noch Platten sind zu hoch ausgelastet. Bei zu hoher Last steigen die Ein-/Ausgabezeiten.

Kanäle haben als Grenzwert zwischen „normaler“ und „zu hoher“ Last eine Auslastung von etwa 60%.

Folgende Tabelle zeigt Grenzwerte für die Auslastung von Platten. Diese Grenzwerte sind vom RAID-Level, von der Read-Hit-Rate und von der Anzahl logischer Volumes auf der physikalischen Platte abhängig. Als Beispiel wurde ein Plattenspeichersystem FibreCAT CX30-20 bei verschiedenen RAID-Leveln mit jeweils 8 Volumes auf den RAID-Gruppen und einem Task pro Volume verwendet (Lasttyp „Random25“, Blockgröße 2 KB).

Auf Basis der Messungen von Ein-/Ausgaben mit 0% Read-Hit wurden unter Berücksichtigung von „annehmbaren“ Ein-/Ausgabezeiten folgende, maximale Ein-/Ausgaberaten für eine Read-Hit-Rate von 80% (= 20% Read-Miss) berechnet:

RAID-Level	max. Ein-/Ausgaben/s
RAID1(1+1)	ca. 1.500
RAID1/0(4+4)	ca. 4.000
RAID5(3+1)	ca. 2.000

Einfluss von logischen Volumes bei Durchsatz-orientiertem Betrieb

Folgende Tabelle zeigt den Gesamtdurchsatz (Mbyte/s), wenn die Last (jeweils ein Task pro Volume mit dem Lasttyp „Sequential Read“ bzw. „Sequential Write“ mit 160 KB pro Ein-/Ausgabe) von einem zu bearbeiteten Volume auf acht zu bearbeitete Volumes gesteigert wird. Alle Volumes liegen auf der gleichen physikalischen Platte eines Plattenspeichersystems FibreCAT CX3-20.

Durchsatz [Mbyte/s]		**Anzahl Volumes (Nutzung: ein Task pro Volume)**							
		1	**2**	**3**	**4**	**5**	**6**	**7**	**8**
RAID1/0	„Seqential Read“	70	100	130	170	165	160	160	160
	„Seqential Write“	55	100	130	90	85	85	85	85
RAID5	„Seqential Read“	70	80	65	65	60	60	60	60
	„Seqential Write“	55	100	120	150	170	180	190	200
RAID1	„Seqential Read“	65	-	-	-	-	-	-	75
	„Seqential Write“	55		-	-	-	-	-	45

Bei den folgenden Messungen wurde die Last (Anzahl Tasks) auf einem Volume gesteigert:

Durchsatz [Mbyte/s]		**Anzahl Tasks pro Volume (Nutzung: 1 - 4 Tasks pro Volume)**							
		1	**2**	**3**	**4**	**5**	**6**	**7**	**8**
RAID1/0	„Seqential Read“	70	130	150	150	-	-	-	-
	„Seqential Write“	55	85	130	140	-	-	-	-
RAID5	„Seqential Read“	70	95	85	80	-	-	-	-
	„Seqential Write“	55	80	110	120	-	-	-	-
RAID1	„Seqential Read“	65	120	90	90	-	-	-	-
	„Seqential Write“	55	60	55	55	-	-	-	-

Zumeist ergibt sich das erwartete Verhalten:
Bei steigender Last erhöht sich zunächst auch der Durchsatz. Ab einer gewissen Grenze sinkt der Durchsatz, im manchen Fällen sogar bis unter den Wert mit einem Volume.

Es gibt Ausnahmen, bei denen der Durchsatz auch bei hoher Last nur wenig sinkt (z.B. „Sequential Read“ bei RAID1/0) bzw. sich dem Maximum annähert (z.B. „Sequential Write“ bei RAID5).

4.3.2 Symmetrix DMX, V-Max

Dieser Abschnitt enthält Messergebnisse über und Folgerungen für die Performance des Plattenspeichersystems Symmetrix DMX-3 (Platten der Größe 146 GB mit 15.000 rpm) bei FC-Anschluss an SX- oder SQ-Server.

Der Durchsatz eines Plattenspeichersystems Symmetrix DMX-4 oder V-Max ist vergleichbar mit dem Durchsatz von DMX-3. Auch die Hardware-Bedienzeiten bei Read-Hit sind vergleichbar. Die Hardware-Bedienzeiten bei Read-Miss sind bei DMX-4 und V-Max kürzer als bei DMX-3.

4.3.2.1 Durchsatz mit einem Task

Die folgenden beiden Tabellen zeigen den erzielten Durchsatz (die Ein-/Ausgaberate in Ein-/Ausgaben pro Sekunde (IO/s) und der Durchsatz in Mbyte/s), den ein Anwendertask bei Plattenzugriffen zum Plattenspeichersystem Symmetrix DMX-3 über FC erreichen kann.

Der Durchsatz wurde für die standardisierten Lasttypen bei verschiedenen Blockgrößen und einer Read-Hit-Rate von 100% für den Plattentyp D3435 bei Datenformat NK2 gemessen:

Eine Task: Ein-/Ausgaben/s	**Blockgröße (KB)**					
	2	**4**	**8**	**16**	**32**	**160**
„Random25“	2.400	2.300	2.050	1.600	1.050	310
„Sequential read“	2.650	2.450	2.150	1.650	1.100	310
„Sequential write“	1.950	2.250	1.700	1.450	1.000	300

Eine Task: Mbyte/s	**Blockgröße (KB)**					
	2	**4**	**8**	**16**	**32**	**160**
„Random25“	5,0	9,5	16	26	35	51
„Sequential read“	5,5	10	17	27	36	52
„Sequential write“	4,0	9,0	14	24	34	48

Aussagen zum Durchsatz des FC-Anschlusses befinden sich auch im Abschnitt „FC-Anschluss“ auf Seite 46.

Das FBA-Plattenformat mit NK2-Datenformat liefert die besten Ergebnisse.

Mit K-Datenformat liegen die Durchsätze niedriger:
um etwa 5-10 % bei kurzen, bis etwa 20-30 % bei großen Blöcken.

4.3.2.2 Hardware-Bedienzeiten

Hardware-Bedienzeiten beim Lesen

Folgende Tabelle zeigt die Ein-/Ausgabezeiten (Hardware-Bedienzeiten) für Read-Hit und Read-Miss, wie sie in üblichen Konfigurationen und bei üblichem Lastaufkommen erreicht werden. Die Zeiten für den Read-Miss werden abhängig vom RAID-Level dargestellt.

Die Hardware-Bedienzeiten sind neben der Ein-/Ausgaberate auch abhängig vom Ausbau des Plattenspeichersystems. Bei den Messungen wurde ein Plattenspeichersystem Symmetrix DMX-3, angeschlossen an einen Server SX160 über 4 FC-Anschlüsse, mit 16 Volumes auf Platten vom Typ D3435 mit Datenformat NK2 und mit geringer gegenseitiger Beeinflussung verwendet. Bei kleinen Konfigurationen können die Zeiten etwas günstiger sein. Bei sehr großen Konfigurationen können die Zeiten schlechter sein.

Ein-/Ausgabezeit Lesen (ms)	**Blockgröße (KB)**					
	2	**4**	**8**	**16**	**32**	**160**
Read-Hit	0,29	0,33	0,41	0,57	0,89	3,4
Read-Miss RAID1	4,8	4,9	5,1	5,4	6,0	11
Read-Miss RAID1/0	4,8	4,9	5,1	5,4	6,0	11
Read-Miss RAID5	5,3	5,4	5,6	6,0	6,8	13

Hardware-Bedienzeiten bei OLTP-Betrieb

Folgende Tabellen zeigen die Ein-/Ausgabezeiten (Hardware-Bedienzeiten) bei unterschiedlichen RAID-Leveln und Read-Hit-Raten, wie sie für einen OLTP-Betrieb (Lasttyp „Random25“) bei üblichen Konfigurationen und üblichem Lastaufkommen erreicht werden.

RAID1(1+1), RAID1/0(4+4)

Ein-/Ausgabezeit „Random25“ [ms]	Blockgröße (KB)					
	2	**4**	**8**	**16**	**32**	**160**
Read-Hit 100%	0,32	0,36	0,44	0,60	0,92	3,5
Read-Hit 80%	1,0	1,0	1,1	1,3	1,7	4,6
Read-Hit 60%	1,7	1,7	1,8	2,0	2,5	5,8

RAID5(3+1)

Ein-/Ausgabezeit „Random25“ [ms]	Blockgröße (KB)					
	2	**4**	**8**	**16**	**32**	**160**
Read-Hit 100%	0,32	0,36	0,44	0,60	0,92	3,5
Read-Hit 80%	1,1	1,1	1,2	1,4	1,8	5,0
Read-Hit 60%	1,8	1,9	2,0	2,2	2,7	6,4

Das FBA-Plattenformat mit NK2-Datenformat liefert die besten Ergebnisse.

Mit K-Datenformat liegen die Hardware-Bedienzeiten höher: um etwa 5-10 % bei kurzen, bis etwa 20-30 % bei langen Blöcken.

RAID6(6+2)

Es gelten die Aussagen von Seite 80 analog.

4.4 LAN-Anschluss

Dieser Abschnitt analysiert die Kommunikationsleistung der BS2000/OSD-Server.

Folgende typische Anwendungsarten werden betrachtet:

- Transaktions-orientierter Betrieb:
  Senden und Empfangen von kurzen Nachrichten (10 Bytes).
  Messwert: Transaktionen pro Sekunde (TA/s).
- Durchsatz-orientierter Betrieb (Massendatentransfer ähnlich File-Transfer):
  Senden bzw. Empfangen von Nachrichten mit einer Länge von 8192 Bytes.
  Messwert: Megabyte pro Sekunde (Mbyte/s).

Die Ergebnisse gelten bei optimalen Bedingungen für eine Socket-Anwendung (TCP/IP), wobei die Nachrichten nicht weiter bearbeitet werden. Die Übertragung der Nachrichten erfolgt von Hauptspeicher zu Hauptspeicher, es finden also keine Plattenzugriffe statt. Bei realen Anwendungen sind deren Anforderungen an CPU und Platten sowie eventuell nicht optimale Netze zu berücksichtigen.

4.4.1 LAN-Anschluss für S-Server

S-Server werden über einen Kanaladapter HNC (High-speed Net Connect) an ein LAN (Local Area Network) angeschlossen.

HNC-IV 91853

Der aktuelle High Speed Net Connect HNC-IV 91853 (kurz: HNC-IV) ist ein hoch performanter Netzanschluss für BS2000-Systeme, siehe Handbuch „HNC-IV 91853“ [14].
Er basiert auf einem Primergy-Server TX300-S3 mit LINUX-Betriebssystem.

HNC-IV unterstützt den Anschluss an einen S-Server über Kanal Typ S und Kanal Typ FC (Fibre Channel) und bedient Ethernet, Fast Ethernet und Gigabit Ethernet LANs.

Nur bei Anschluss des HNC-IV über Kanal Typ FC kann die hohe Durchsatzleistung des Gigabit LAN bei der Datenübertragung auf der Kanalseite entsprechend genutzt werden.

Der Einsatz des HNC-IV wird in folgenden Fällen empfohlen:

- wenn die Leistung der Kanäle Typ S nicht ausreicht und deshalb der Einsatz von Kanal Typ FC (Fibre Channel) erforderlich wird
- wenn der Durchsatz der installierten Netzanschlüsse nicht mehr ausreicht
- wenn bestehende CSMA/CD-Netze durch Gigabit Ethernet LAN ergänzt werden
- wenn mehrere Server (oder auch VM2000-Systeme) miteinander verbunden werden sollen
- wenn das VLAN-Protokoll (IEEE 802.1q) in BCAM genutzt werden soll

Die erreichbaren Transaktionsraten und Durchsatzwerte in den folgenden Abschnitten wurden mit dem HNC-IV bei Anschluss über Kanal Typ S und Typ FC gemessen. Verglichen werden sie mit den Messwerten des Vorgängermodells HNC-IIIR 91852 (kurz: HNC-IIIR).

Es werden nur Gigabit Ethernet LANs (1.000 Mbit/s) betrachtet. Dabei wird unterschieden zwischen den Standardeinstellungen mit einer Maximum Transmission Unit (MTU) von 1.500 Bytes und Jumbo Frames mit einer MTU von 9.000 Bytes. Bei Jumbo-Frames müssen Netz, Switches und Partner-Systeme ebenfalls für Jumbo-Frames konfiguriert sein.

Beim Einsatz von Fast Ethernet muss die niedrigere Bandbreite (100 Mbit/s) beachtet werden. So begrenzt bei einem Fast Ethernet LAN und einem Kanal Typ S bei einseitigen Lasten das Netz den Durchsatz. Bei beidseitigen Lasten oder wenn zwei Fast Ethernet LANs angeschlossen sind, begrenzt der Kanal Typ S den Durchsatz bei etwa 12 Mbyte/s.

HNC an Kanal Typ S

Folgende Tabelle zeigt die Messergebnisse für einen Server S190-40 (4 CPUs, 1060 RPF), der mit einem Kanaladapter **HNC-IV 91853** an ein Gigabit LAN mit einer MTU von 1.500 Bytes angeschlossen ist.
Zwischen Server und HNC wurden alternativ ein Kanal bzw. zwei Kanäle konfiguriert. Bei zwei Kanälen wird automatisch eine Lastverteilung erreicht. Beim Ausfall eines Kanals ist ein unterbrechungsfreier Betrieb gewährleistet.
Die Messung erfolgte mit openNet Server V3.2 (BCAM V19.0, SOCKETS_BS2000 V2.3):

HNC-IV 91853 Gigabit Ethernet (1.000 Mbit/s) (Maximum Transfer Unit: 1.500 Bytes)				
Kanal-Anschluss	1 Kanal Typ S		2 Kanäle Typ S	
Anzahl Verbindungen	120	600	120	400
Transaktionen [TA/s] CPU [%] Kanal [%]	25.000 30 1 * 50	50.000 60 1 * 60	45.000 60 2 * 55	60.000 85 2 * 60
	Senden	Empfangen	Senden	Empfangen
Durchsatz [Mbyte/s] CPU [%] Kanal [%]	14 10 1 * 95	12 10 1 * 80	30 20 2 * 95	30 20 2 * 95

Die Transaktionsraten können gegenüber dem Vorgängermodell HNC-IIIR 91852 gesteigert werden. Der LAN-Durchsatz wird in allen Messungen durch den Kanal Typ S begrenzt.

Werte mit JUMBO-Frames fehlen, da der LAN-Durchsatz durch JUMBO-Frames, bedingt durch die Grenzen des Kanals Typ S, nicht erhöht werden kann.

Die Transaktionsrate kann mit zunehmender Anzahl von Verbindungen gesteigert werden.

Die maximalen Transaktionsraten liegen in allen Fällen deutlich über den heute üblichen Anforderungen, z.B. von OLTP-Anwendungen.

Um Hochleistungsnetze ausnutzen zu können, ist eine ausreichende CPU-Kapazität erforderlich. Die Auslastung des Servers S190-40, allein durch die Kommunikation, beträgt bei 60.000 TA/s etwa 85%.

Die folgenden Tabellen zeigen zum Vergleich die Messergebnisse für einen Server S170-40 (4 CPUs, 650 RPF), der mit einem Kanaladapter **HNC-IIIR 91852** an ein Gigabit LAN mit einer MTU von 1.500 bzw. 9.000 Bytes angeschlossen ist.
Zwischen Server und HNC wurden alternativ ein Kanal bzw. zwei Kanäle konfiguriert.
Die Messung erfolgte mit openNet Server V3.1 (BCAM V18.0, SOCKETS_BS2000 V2.2):

HNC-IIIR 91852 Gigabit Ethernet (1.000 Mbit/s) (Maximum Transfer Unit: 1.500 Bytes)				
Kanal-Anschluss	1 Kanal Typ S		2 Kanäle Typ S	
Transaktionen [TA/s] CPU [%] Kanal [%]	24.000 50 55		44.000 80 2 * 55	
	Senden	Empfangen	Senden	Empfangen
Durchsatz [Mbyte/s] CPU [%] Kanal [%]	13 15 85	12 10 80	25 25 2 * 85	24 20 2 * 80

HNC-IIIR 91852 Gigabit Ethernet (1.000 MBit/s) (Maximum Transfer Unit: 9.000 Bytes)				
Kanal-Anschluss	1 Kanal Typ S		2 Kanäle Typ S	
Transaktionen [TA/s] CPU [%] Kanal [%]	18.000 45 50		34.000 70 2 * 50	
	Senden	Empfangen	Senden	Empfangen
Durchsatz [Mbyte/s] CPU [%] Kanal [%]	15 15 95	15 10 95	30 25 2 * 95	30 15 2 * 95

Bei einem Gigabit Ethernet LAN wird der Durchsatz auch vom Kanal Typ S begrenzt. Wird ein zweiter Kanal Typ S verwendet, kann der Durchsatz verdoppelt werden.

Die maximalen Transaktionsraten können mit einem zweiten Kanal Typ S nochmals gesteigert werden.

HNC an Kanal Typ FC

Folgende Tabelle zeigt die Messergebnisse für einen Server S190-40 (4 CPUs, 1060 RPF), der mit einem Kanaladapter **HNC-IV 91853** an ein Gigabit LAN mit einer MTU von 1.500 bzw. 9.000 Bytes angeschlossen ist.
Zwischen Server und HNC wurde ein Kanal Typ FC konfiguriert.
Die Messung erfolgte mit openNet Server V3.3 (BCAM V20.0, SOCKETS_BS2000 V2.4):

HNC-IV 91853 Gigabit Ethernet (1.000 Mbit/s)				
Kanal-Anschluss	1 Kanal Typ FC			
MTU [Bytes]	1.500		9.000	
Transaktionen [TA/s] CPU [%]	85.000 95		80.000 95	
	Senden	Empfangen	Senden	Empfangen
Durchsatz [Mbyte/s] CPU [%]	55 35	70 40	60 25	75 25

Bei einem Gigabit Ethernet LAN und einem Kanal Typ FC wird der LAN-Durchsatz gegenüber dem Kanal Typ S um den Faktor 4 bis 5 gesteigert.

Maximal können mehr als 80.000 Transaktionen pro Sekunde erreicht werden. Ein Server S190-40 ist dann, allein durch die Kommunikation, fast ausgelastet.

Bei einer MTU von 9.000 Bytes ist die Transaktionsrate ca. 5% geringer, der Durchsatz ca. 10% höher als bei einer MTU von 1.500 Bytes.

Vergleich HNC-IV 91853 mit HNC-IIIR 91852

Der Durchsatz kann mit dem HNC-IV gegenüber dem HNC-IIIR um ca. 10 - 20% gesteigert werden.

Durch die Unterstützung des Kanals Typ FC erreicht der HNC-IV gegenüber dem HNC-IIIR (nur Kanal Typ S) eine maximale Durchsatzsteigerung um den Faktor 5 bis 7.

Die Transaktionsraten lassen sich beim HNC-IV gegenüber dem HNC-IIIR bei höherer Last deutlich von ca. 25.000 TA/s auf 50.000 TA/s steigern.

Wesentlichen Anteil an den erzielten Verbesserungen haben die Tuning-Maßnahmen in openNet Server V3.2 (höhere Kettung), wobei die maximalen 128 KB Frame-Puffer pro Ein-/Ausgabe genutzt werden. In openNet Server V3.1 / BCAM V18.0 war der Frame-Puffer auf 64 KB begrenzt.

Mehrere Virtual Channel Adapter (VCA)

Ein leistungsstarker Server hat eine IP-Adresse und einen VCA. Bei Nutzung mehrerer IP-Adressen, z.B bei Anschluss mehrerer virtueller Maschinen eines VM2000-Systems oder auch bei mehreren LAN-Anschlüssen am HNC, können mehrere VCAs generiert werden.

Nährere Informationen dazu finden Sie in den Handbüchern „BCAM“ [1] (VLAN-Betrieb) und „HNC-IV 91853“ [14].

Bei Nutzung mehrerer VCAs und einem HNC-Anschluss über zwei FC-Kanäle lässt sich der maximale Durchsatz beim Senden auf ca. 115 Mbyte/s, beim Empfangen auf ca. 90 Mbyte/s steigern.

Homogene Kopplung

Bei der Kopplung zweier virtueller Maschinen auf einem Server S190-40 über einen HNC-IV werden folgende Werte erreicht:

- Die maximale Transaktionsrate beträgt ca. 30.000 TA/s.
  Die BS2000-CPUs sind dann beim Client zu ca. 40% und beim Server zu ca. 45% ausgelastet. Die Antwortzeiten liegen bei ca. 1 ms.
- Der maximale Durchsatz liegt bei einer MTU von 1.500 beim Empfang bei ca. 40 Mbyte/s, beim Senden bei ca. 50 Mbyte/s.
  Die BS2000-CPUs sind zu ca. 25% ausgelastet.

Durchsatz mit einer Verbindung

Mit einer (TCP-)Verbindung sind zu einem leistungssstarken Partnersystem folgende Werte möglich:

LAN	**Durchsatz (Mbyte/s)**	
Kanal-Anschluss	**Typ S**	**Typ FC**
Fast Ethernet	10 - 11	10 - 11
Gigabit Ethernet (Ethernet Frames)	12 - 14	60 - 75
Gigabit Ethernet (Jumbo Frames)	12 - 15	65 - 80

Diese Werte werden bei weniger leistungsstarken Partnersystemen nicht erreicht.
Sie können ebenfalls nicht erreicht werden, wenn andere Komponenten, wie Platten oder ein nicht optimales Netz, den Datentransfer bremsen.

Die besten Antwortzeiten zwischen einem BS2000-System und einem über Fast Ethernet oder Gigabit Ethernet verbundenen Partnersystem liegen für kurze Nachrichten bei 0,7 Millisekunden.

Formel für Serverleistung

Als Faustformel für die Serverleistung, die alleine durch die Kommunikation ab der Sockets-Schnittstelle (ohne Verarbeitung der Nachrichten) benötigt wird, gilt bei Fast Ethernet und Gigabit Ethernet LAN:

- MTU 1.500 Bytes
  - 60 - 90 Transaktionen pro RPF
  - 0,10 - 0,20 Mbyte/s pro RPF
- MTU 9.000 Bytes
  - 60 - 80 Transaktionen pro RPF
  - 0,20 - 0,30 Mbyte/s pro RPF

4.4.2 LAN-Anschluss für SX-Server

SX-Server werden über einen integrierten Controller (PCI-Controller) an ein LAN angeschlossen. Die Ein-/Ausgaben zum integrierten Controller werden, wie alle Ein-/Ausgaben, über den I/O-Prozessor geleitet (siehe Abschnitt „I/O-Prozessor (X2000)“ auf Seite 45). Der LAN-Anschluss über integrierte Controller wird aus Performance-Sicht für alle SX-Server empfohlen. Ein LAN-Anschluss über HNC wird daher für die aktuellen SX-Server nicht mehr angeboten.

Folgende Tabelle zeigt die Messergebnisse für den integrierten 4-Port Gigabit Ethernet Controller CL21 und ein LAN mit einer MTU von 1.500 bzw. 9.000 Bytes. Sie beziehen sich auf einen Server SX160-60C. Die in der Tabelle angegebenen Maximalwerte werden mit mehreren parallelen (TCP-)Verbindungen erreicht.

Gigabit Ethernet (1.000 Mbit/s)				
MTU [Bytes]	1.500		9.000	
Transaktionen [TA/s] CPU [%] IOP [%]	40.000 85 75		35.000 85 75	
	Senden	Empfangen	Senden	Empfangen
Durchsatz [Mbyte/s] CPU [%] IOP [%]	60 50 95	50 25 100	100 50 95	100 25 100

Die maximalen Transaktionsraten liegen deutlich über allen heute üblichen Anforderungen, z.B. von OLTP-Anwendungen. Die Transaktionsrate wird in der Regel durch die Vollauslastung der BS2000-CPUs begrenzt.

Um Hochleistungsnetze ausnutzen zu können, ist eine ausreichende CPU-Kapazität erforderlich. Soweit nicht die Grenzen des LANs erreicht werden, erhöht sich mit der Anzahl CPUs auch die erreichbare Leistung.

Mit nur einer Verbindung sind folgende Werte möglich :

LAN	**Durchsatz (Mbyte/s)** **SX160-60C**
Fast Ethernet	10 - 11
Gigabit Ethernet / Ethernet Frames	30 - 55
Gigabit Ethernet / Jumbo Frames	30 - 100

Diese Werte können nur bei leistungsstarken Partnersystemen und einer optimalen Netzkonfiguration erreicht werden.

4.4.3 LAN-Anschluss für SQ-Server

SQ-Server werden über einen integrierten Controller (PCI-Controller) an ein LAN angeschlossen. Die Ein-/Ausgaben zum integrierten Controller werden, wie alle Ein-/Ausgaben, über den I/O-Prozessor geleitet (siehe Abschnitt „I/O-Prozessoren (X2000)“ auf Seite 48).

Folgende Tabelle zeigt die Messergebnisse für den integrierten 2-Port Gigabit Ethernet Controller und ein LAN mit einer MTU von 1.500 bzw. 9.000 Bytes. Sie beziehen sich auf einen Server SQ100-40D. Die in der Tabelle angegebenen Maximalwerte werden mit mehreren parallelen (TCP-)Verbindungen erreicht.

Gigabit Ethernet (1.000 Mbit/s)				
MTU [Bytes]	1.500		9.000	
Transaktionen [TA/s] CPU [%] IOP [%]	10.000 100 5		10.000 100 5	
	Senden	Empfangen	Senden	Empfangen
Durchsatz [Mbyte/s] CPU [%] IOP [%]	70 100 55	50 50 5	110 100 5	110 45 10

Die maximalen Transaktionsraten liegen deutlich über allen heute üblichen Anforderungen, z.B. von OLTP-Anwendungen. Die Transaktionsrate wird in der Regel durch die Vollauslastung der BS2000-CPUs begrenzt.

Um Hochleistungsnetze ausnutzen zu können, ist eine ausreichende CPU-Kapazität erforderlich. Soweit nicht die Grenzen des LANs erreicht werden, erhöht sich mit der Anzahl CPUs auch die erreichbare Leistung.

Mit nur einer Verbindung sind folgende Werte möglich :

LAN	**Durchsatz (Mbyte/s)** **SX160-60C**
Fast Ethernet	10 - 11
Gigabit Ethernet / Ethernet Frames	30 - 50
Gigabit Ethernet / Jumbo Frames	30 - 100

Diese Werte können nur bei leistungsstarken Partnersystemen und einer optimalen Netzkonfiguration erreicht werden.

4.4.4 Hilfsmittel zur Leistungskontrolle

BCMON

Das BCMON-Kommando startet eine zyklische BCAM-Überwachung und gibt die gewünschten Werte in regelmäßigen Abständen aus.
Die Ausgabe der Werte erfolgt über den Bedienplatz und zusätzlich in die Protokolldatei (`$SYSAUDIT.SYS.CONSLOG.<date>.<counter>`), so dass die Werte später analysiert werden können. Siehe auch Handbuch „BCAM“ [1].

Einfaches Beispiel für BCMON

Dieses Beispiel zeigt die Messung des Durchsatzes einer spezifischen Verbindung. Ohne Angabe von `LINE=` ist auch die Messung des Gesamt-Durchsatzes möglich.

`/BCMON MODE=ON,RECORD=L2,LINE=LINEFCGB,SEC=30` (Kommando am Bedienplatz)

Alle 30 Sekunden werden die in dieser Zeit aufgelaufenen Messwerte ausgegeben, z.B.:

```
<C %BCAM-000... %  BCA0B15 Line LINEFCGB:
BYTES=(I=929.088.154/O=930.140.116); I/O'S=(I=50.259/O=33.216);
PACKETING=(I=4,60/O=6,98) ──────────────────────────────────────────  (1)
<C %BCAM-000... %  BCA0B16 Line LINEFCGB: UNICASTs=(I=231.372/O=231.981);
MULTICASTs=(I=0/O=0) ───────────────────────────────────────────────  (2)
<C %BCAM-000... %  BCA0B17 Line LINEFCGB: I/O ERRORs=(I=0/O=0);
WAIT+RETRIES=0; DISCARDS=(I=0/O=0); PROTOCOL ERRORs=(I=0/O=0);
L2 PROTOCOLs=(I=0/O=0) ──────────────────────────────────────────────  (3)
```

(1) `Line LINEFCGB` : Name der Leitung
`BYTES=(I=` : Anzahl der empfangenen Bytes
`BYTES=(O=` : Anzahl der gesendeten Bytes
`I/O'S=(I=` : Anzahl der Eingaben
`I/O'S=(O=` : Anzahl der Ausgaben
`PACKETING=(I=` : Anzahl der Nachrichten pro Eingabe
`PACKETING=(O=` : Anzahl der Nachrichten pro Ausgabe

(2) `Line LINEFCGB` : Name der Leitung
`UNICASTs=(I=` : Anzahl der empfangenen UNICASTs
`UNICASTs=(O=` : Anzahl der gesendeten UNICASTs
`MULTICASTs=(I=` : Anzahl der empfangenen MULTICASTs
`MULTICASTs=(O=` : Anzahl der gesendeten MULTICASTs

(3) Die Meldung `BCA0B17` ist lediglich ein Fehlerzähler

NETSTAT

Das Programm NETSTAT ermöglicht die Abfrage von Informationen über Anwendungen, Verbindungen, Routing-Daten und Netzanschlüsse. Die Funktionalität des Programms NETSTAT steht auch via BCAM-Kommando SHOW-NET-STATISTICS/NETSTAT zur Verfügung. Das Programm NETSTAT kann mit dem SHOW-NET-STATISTICS/NETSTAT Kommando unter jeder beliebigen Benutzerkennung ohne Privilegierung genutzt werden.
Siehe auch Handbuch „BCAM“ [1].

Einfaches Beispiel für NETSTAT

Dieses Beispiel zeigt die Messung des Gesamt-Durchsatzes mit NETSTAT.

/netstat interface-sum-rate=*yes,waittime=30 (Benutzer-Kommando)

Nach den Lademeldungen und einer Anzeige der derzeit aufgelaufenen Werte werden alle 30 Sekunden die normierten Werte für die Eingaben und Ausgaben (jeweils in Paketen und Bytes) ausgegeben:

```
%  BLS0523 ELEMENT 'BS2NETSTAT', VERSION '01.0A05', TYPE 'L' FROM LIBRARY
':2OSH:$TSOS.SYSPRG.BCAM.190' IN PROCESS
%  BLS0524 LLM 'BS2NETSTAT', VERSION '01.0A05' OF '2004-10-18 10:19:50'
LOADED

Date: Mon Jan 28 14:40:02 2008
  PacketsIn     BytesIn    ErrorsIn  PacketsOut    BytesOut   ErrorsOut
  146825688  1628891483           0    58425736   475395828          64

  dt(s)    PktsIn/s   BytesIn/s   ErrIn   PktsOut/s  BytesOut/s  ErrOut
 30.003      160.78    32971.37       0      218.88   103516.65       0
 30.003      121.12    29132.09       0      141.75    56346.17       0
 30.004      596.05    50922.44       0     1112.42   637658.05       0
 30.012      722.54    59018.83       0     1362.69   787110.16       0
```

openSM2

Folgende SM2-Messprogramme liefern wichtige Informationen zum Networking (siehe Handbuch „openSM2“ [19]):

- BCAM-CONNECTION
  Messdaten für Verbindungen
- CHANNEL-IO
  Messdaten zur Kanalauslastung und Kanalübertragungsraten.
  Die Auslastung des Kanals Typ FC bei Anschluss eines HNC-IV 91853 kann mit SM2-Mitteln nicht gemessen werden.
- PERIODIC TASK
  Messdaten über Tasks: Auslastung der BCAM-Tasks (z.B. BCAM und BCA0)
- RESPONSETIME
  Messdaten über Antwortzeiten, Denkzeiten, Transaktionszeiten und Nachrichtenwartezeiten im BCAM-Pool
- SAMPLING-DEVICE
  Messdaten über Ein-/Ausgaben, Datenmenge und Auslastung von Geräten
- TCP-IP
  Messdaten zu TCP/IP-Verbindungen

4.5 Dateiverschlüsselung

Einzelne Dateien können verschlüsselt werden.
Voraussetzung für die Dateiverschlüsselung ist die Produktfamilie openCRYPT.

openCRYPT bietet die Verschlüsselungsschnittstellen (PKCS#11) für beliebige BS2000-Anwendungen an. Die Schnittstellen sind für alle BS2000/OSD-Server gleich. Die Verschlüsselungsschnittstellen werden auch von anderen Produkten genutzt (z.B. openFT).

Für die Verschlüsselung ist separate Hard- und Software notwendig:

	Hardware	**Software**
S-Server	openCRYPT-BOX™ (Krypto-Box)	openCRYPT™-SERV
SX-Server **SQ-Server**	1 oder 2 dedizierte Krypto-CPUs [1]	openCRYPT™-SERV und openCRYPT™-SOFT

[1] auf SX100 erledigt das der I/O-Prozessor

Die eigentliche Verschlüsselung wird auf der externen Hardware (Krypto-Box oder Krypto-CPU) durchgeführt, da die Verschlüsselung rechenintensiv ist und die BS2000-CPUs zu sehr belasten würde.

4.5.1 Ablauf beim Zugriff auf eine verschlüsselte Datei

Beim Schreiben auf Platte wird die Datei in einem Schritt seitenweise verschlüsselt. Beim Lesen von Platte wird die Datei entschlüsselt.

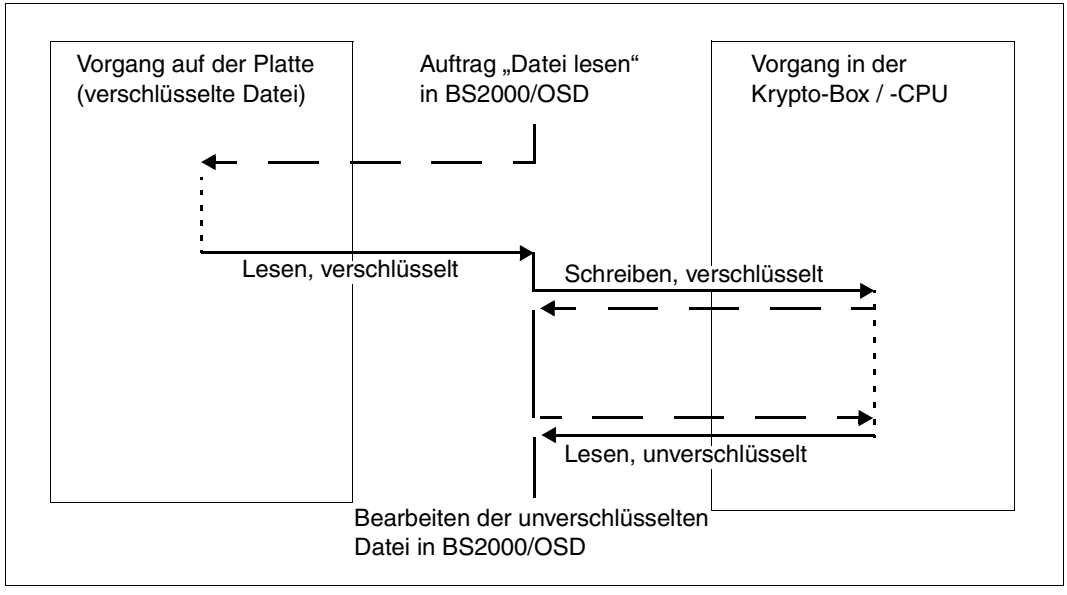

Bild 5: Ablaufschema beim Lesen einer verschlüsselten Datei

Bei einer verschlüsselten Datei kommen für jede Platten-Ein-/Ausgabe zwei zusätzliche Krypto-Ein-/Ausgaben hinzu (Lesen und Schreiben für die Krypto-Box oder Krypto-CPU).

Dies hat Performance-Auswirkungen auf

- Antwortzeiten
- Laufzeiten von Batch-Jobs
- CPU-Bedarf
- CPU-Auslastung
- den maximal erreichbaren Durchsatz

Das Ausmaß der Auswirkungen hängt ab

- von der Blockgröße der Ein-/Ausgaben (größere Blöcke sind stärker betroffen)
- vor allem vom Anteil der verschlüsselten Ein-/Ausgaben an der Gesamtzahl der Ein-/Ausgaben

Da der Mehrbedarf nur bei Platten-Ein-/Ausgaben anfällt, wird er durch den Einsatz von Lesepufferung (in ISAM, in Datenbanken oder durch DAB) deutlich verringert.

Das Transferieren einer verschlüsselten Datei beim Kopieren oder beim Sichern und Rekonstruieren erfolgt stets in verschlüsselter Form. Es entfallen bei allen Dateizugriffen die Krypto-Ein/Ausgaben und damit auch alle Performance-Auswirkungen.

4.5.2 Konfigurations-Empfehlungen für S-Server

Wenn Dateiverschlüsselung verwendet wird, dann ist der Einsatz von Lesepufferung zu empfehlen (mit DAB, wenn keine andere Pufferung durch ISAM oder in Datenbanken wirkt).

Standardmäßig wird bei der Dateiverschlüsselung mit dem symmetrischen Verschlüsselungsverfahren AES (128 Bit) gearbeitet. Wahlweise kann auch DES (64 Bit) eingestellt werden. AES ist aus Performance-Sicht deutlich günstiger und zudem aus Sicherheitsgründen eindeutig vorzuziehen.

Krypto-Box

Um Wartezeiten zu vermeiden, sollte folgender maximaler Durchsatz pro Kanal Typ S einer Krypto-Box im Dauerbetrieb nicht überschritten werden:

- 1000 - 1500 Krypto-Ein-/Ausgaben pro Sekunde (kleine Blöcke, z.B. TP-Betrieb)
- 5 - 8 MB/s (große Blöcke, z.B. Batch-Job)

Zur Ausfall-Sicherheit ist für die Dateiverschlüsselung der Einsatz von zwei Krypto-Boxen mit möglichst je zwei Kanälen vom Typ S zu empfehlen. In einem Sicherheitsverbund können sich auch mehrere BS2000-Systeme zwei Krypto-Boxen teilen. Die eingesetzten Krypto-Boxen können parallel zur Dateiverschlüsselung und z.B. auch zur Datenverschlüsselung bei openFT genutzt werden. (Dies ist bei einer Leistungsabschätzung zu berücksichtigen.)

Bei TP-Betrieb und einem Verschlüsselungsanteil von 25% aller Platten-Ein-/Ausgaben reichen zwei Krypto-Boxen (mit je zwei Kanälen Typ S) für einen S-Server mit 800 RPF.

Der Anteil der Krypto-Ein-/Ausgaben kann mit den SM2-Reports ACTIVITY oder CHANNEL gemessen werden.

4.5.3 Beispiele mit Performance-Auswirkungen

Bei der Bewertung der folgenden Beispiele sind die genannten Annahmen zu beachten. Die Auswirkungen sind im Wesentlichen vom Anteil der verschlüsselten Ein-/Ausgaben an der Gesamtzahl der Ein-/Ausgaben abhängig.

Für die Abschätzung eines TP-Betriebs wird ein Anteil verschlüsselter Ein-/Ausgaben von 25% angenommen. Es ist mit folgenden Auswirkungen zu rechnen:

- Antwortzeit:
  kaum spürbar
- CPU-Bedarf und CPU-Auslastung:
  Erhöhung ohne DAB etwa 5 - 10%, mit DAB unter 5%

Bei einem Batch-Lauf wird ein Anteil verschlüsselter Ein-/Ausgaben von 50% angenommen. Die Laufzeit soll sich zusammensetzen aus 1/3 CPU-Zeit und 2/3 Ein-/Ausgabezeit. Es ist mit folgenden Auswirkungen zu rechnen:

- Laufzeit:
  Ohne DAB verdoppelt sich die Laufzeit, mit DAB kann der Zuwachs auf 15% begrenzt werden.
- CPU-Bedarf und CPU-Auslastung:
  Der CPU-Bedarf erhöht sich zwar, wegen der längeren Laufzeit verringert sich aber die CPU-Auslastung.

Mit einer Krypto-Box (S-Server) bzw. einer Krypto-CPU (SX-/SQ-Server) kann beispielsweise folgender maximaler Durchsatz erreicht werden.
(Ein/Ausgaberate mit kleinen Blöcken bzw. Durchsatz mit großen Blöcken unter Beachtung der Konfigurations-Empfehlungen.)

- S-Server mit Krypto-Box, Anschluss über einen Kanal Typ S:
  3000 Ein-/Ausgaben pro Sekunde bzw. 8 MB/s
- S-Server mit Krypto-Box, Anschluss über vier Kanäle Typ S:
  8000 Ein-/Ausgaben pro Sekunde bzw. 30 MB/s
- SX-Server SX160 mit einer Krypto-CPU:
  5000 Ein-/Ausgaben pro Sekunde bzw. 20 MB/s

5 Datensicherung

Die Leistungsfähigkeit von Plattenspeichersystemen (Online-Peripherie) und Bandspeichersystemen (Nearline-Peripherie) ist in den letzten Jahren kontinuierlich gestiegen. In diesem Zusammenhang haben sich Verbindungen vom Server zur Speicher-Peripherie in Fibre Channel Technologie zum Standard für offene Server-Systeme entwickelt.

An den SX-Servern ist Fibre Channel die Standard-Anschlusstechnik für Platten- und Bandperipherie. Auch bei den S-Servern wurde durch den Kanal Typ FC der Übergang zum Fibre Channel Anschluss für moderne Hochleistungsperipherie geschaffen.

Für eine optimale Performance bei der Datensicherung ist ein ausgewogener und kombinierter Einsatz von Online- und Nearline-Systemen erforderlich. Die Konfiguration solcher Systeme muss am Sicherungsumfang und an den verfügbaren Zeitfenstern für die Datensicherung ausgerichtet werden. Dieser Abschnitt stellt dafür grundlegende Informationen bereit.

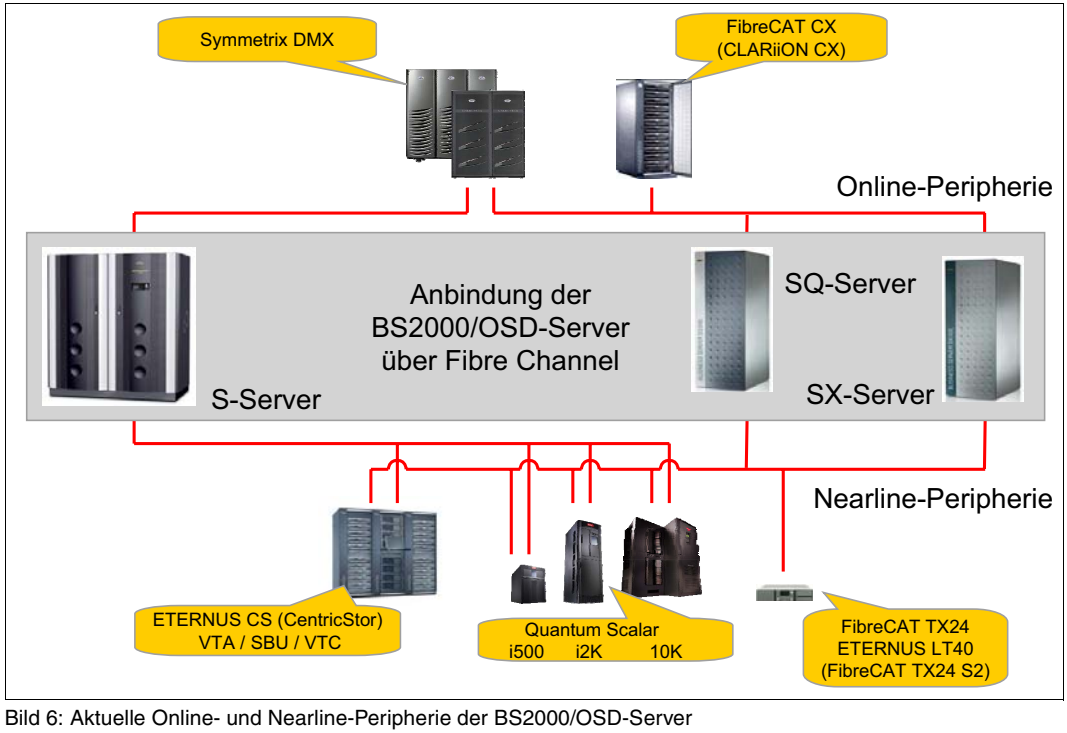

Bild 6: Aktuelle Online- und Nearline-Peripherie der BS2000/OSD-Server

Formen der Datensicherung in BS2000/OSD

Es gibt zwei Formen der Datensicherung:

- Bei der **logischen** Datensicherung werden Dateien und Jobvariablen von einem oder mehreren Datenträgern (z.B. logische Volumes auf Plattenspeichern) gelesen und zusammenhängend auf einen oder mehrere Datenträger (z.B. Magnetbandkassetten) geschrieben, d.h. einzelne Dateien und Jobvariablen werden einzeln gesichert und können einzeln restauriert werden.
  Für die logische Datensicherung steht in BS2000/OSD das Softwareprodukt HSMS/ARCHIVE zur Verfügung (siehe Handbuch „HSMS/HSMS-SV“ [15]).
- Bei der **physikalischen** Datensicherung werden keine einzelnen Dateien gesichert, sondern ganze Datenträger (z.B. Platten). Dabei werden sämtliche Daten eines Datenträgers, einschließlich der Datenkennsätze, blockweise in der physikalischen Reihenfolge auf einen zweiten Datenträger (z.B. Magnetbandkassette) geschrieben. Dieser ist somit in Aufbau und Inhalt identisch mit dem Originaldatenträger.
  Für die physikalische Datensicherung steht in BS2000/OSD das Softwareprodukt FDDRL zur Verfügung (siehe Handbuch „FDDRL“ [12]).

Sicherungsvolumen

Zur Errechnung des Sicherungsvolumens bei der **logischen** Datensicherung werden folgende Erfahrungswerte zu Grunde gelegt.

- Vollsicherung: kompletter aktiver Datenbestand
- Differenzsicherung:
  täglich ca. 5% des kompletten Datenbestandes
  wöchentlich ca. 15% des kompletten Datenbestandes
  Dabei wird in einer Differenzsicherung nicht die Differenz zur letzten Vollsicherung gebildet, sondern für jede Datei die Differenz zu allen vorherigen Sicherungen

Der Bedarf an Sicherungsmedien errechnet sich bei Fortsetzung von Sicherungsbändern aus Zahl und Volumen der Gesamt- und Differenzsicherungen.

Beispiel

Es werden pro Monat eine Vollsicherung (Anzahl der archivierten Vollsicherungsbestände: 3) und pro Tag eine Differenzsicherung durchgeführt.
Damit ergibt sich ein Sicherungsbestand vom gut 4-fachen des aktiven Datenbestandes (`3 * 100% + 25 * 5% = 425%`).

Bei der **physikalischen** Datensicherung eines Volumes überträgt FDDRL (Funktion DUMP) standardmäßig nur die Bereiche, die im F5-Kennsatz als belegt gekennzeichnet sind. Damit werden i.d.R. bei der physikalischen Sicherung mit FDDRL nicht mehr Daten übertragen als bei der logischen Sicherung mit HSMS. Bei physikalischen Sicherungen kann aber keine Differenzsicherung erstellt werden.

5.1 Logische Datensicherung mit HSMS/ARCHIVE

Mit HSMS/ARCHIVE werden sowohl BS2000- als auch POSIX-Dateien des lokalen BS2000-Systems gesichert.

Neben der Datensicherung (SAVE) ist auch die Datenrekonstruktion (RESTORE) zu betrachten. Bei der (gegenüber der Sicherung seltenen) Wiederherstellung der gesicherten Daten gelten etwas andere Durchsatzwerte als bei der Sicherung. Diese sind jedoch i.d.R. erst dann kritisch, wenn eine vollständige Sicherung eingespielt werden soll. Bei der Rekonstruktion einzelner Dateien, die parallel zum normalen Betrieb läuft, spielt der Durchsatz eine untergeordnete Rolle.

Parallelität

Mit HSMS können mehrere Aufträge parallel ausgeführt werden. Der Grad dieser Parallelität kann durch die Anzahl der HSMS-Servertasks vorgegeben werden.

In einem Auftrag wiederum kann mit parallelen Datenströmen (auf mehrere Bandgeräte) gearbeitet werden. Dies wird mit dem Operanden `PARALLEL-RUNS` in der Aktionsanweisung oder als Archiv-Attribut gesteuert.

Mit HSMS/ARCHIVE werden außerdem beim Lesen von der Platte (Save) bzw. beim Schreiben auf die Platte (Restore) asynchrone Ein-/Ausgaben erzeugt.
Diese Ein-/Ausgaben werden parallel ausgeführt, wenn die Funktion Parallel Access Volume (PAV) des Plattenspeichersystems zusammen mit einem geeignetem RAID-Level genutzt wird (siehe Seite 69).

Parallele Datenströme und parallele Ein-/Ausgaben führen beim Sichern zu kürzeren Sicherungszeiten.

HSMS/ARCHIVE-Directory

Das HSMS-Directory ist eine ISAM-Datei, in der alle Informationen über die gesicherten Datenbestände und die zugehörigen Datenträger hinterlegt sind.

Bei großer Anzahl zu sichernder Dateien und vielen Sicherungen hat das HSMS-Directory einen entsprechend großen Umfang. Beim Sichern werden die gesicherten Dateistände in das HSMS-Directory geschrieben, beim Restaurieren daraus gelesen. Zusätzlich muss bei Differenzsicherung noch gelesen werden, ob der aktuelle Dateistand schon im Sicherungsbestand enthalten ist. Die Zugriffe auf das HSMS-Dirctory erfolgen in der ARCHIVE-Maintask parallel zum eigentlichen Sichern der Dateien in den Subtasks. Das Reporting erfolgt ebenso in der ARCHIVE-Maintask in ISAM-Dateien.

Die Directory-Verarbeitung wird durch eine gute Lesepufferung in ISAM zur Vermeidung von physikalischen Ein-/Ausgaben beschleunigt. Hierzu ist ein entsprechend großer systemglobaler ISAM-Pool `$SYS01` erforderlich. Die Größe kann im Parametersatz ISAM eingestellt werden mit: `BEGIN ISAM GLBDFPS=<größe des isam-pools>`.

Eine Größe von 8192 wird zur Verbesserung aller ISAM-Zugriffe empfohlen (an Stelle des Standardwertes 512).

Dateigrößen

Bei der logischen Datensicherung werden Dateien betrachtet. Für jede Datei entsteht ein gewisser Grundaufwand. Einen wesentlichen Einfluss auf den Durchsatz haben daher bei der logischen Datensicherung mit HSMS/ARCHIVE die Dateigrößen. Abhängig von der mittleren Dateigröße kann der Durchsatz mit vielen kleinen Dateien deutlich geringer ausfallen als im optimalen Fall mit wenigen sehr großen Dateien.

Große Bandblöcke

Um der kontinuierlichen Entwicklungen neuer Bandspeichersysteme Rechnung zu tragen, unterstützen HSMS/ARCHIVE und BS2000/OSD so genannte „große Bandblöcke“ (bis 256 KB). Mit diesen „großen Bandblöcken“ können bei Bandverarbeitung deutliche Leistungsverbesserungen (bis Faktor 2) gegenüber den bisherigen „Standard-Bandblöcken“ (bis 32 KB) erreicht werden.

Parallele Auftragspakete

Die ARCHIVE-Maintask generiert beim Sichern von DMS-Dateien kleine Auftragspakete und übergibt diese an die nächste freie Subtask zur Ausführung.

Die kleinen Auftragspakete sorgen für eine schnellere, parallele Sicherung (auch von nur einer Kennung und einem Katalog) sowie für eine gleichmäßigere Auslastung der Subtasks und eine bessere Überlappung von Subtasks und Maintask. Der Nachlauf nach dem Schließen der Bänder kann dadurch verkürzt werden. Die Verbesserung ist im Wesentlichen von der Anzahl paralleler Läufe (Runs), Anzahl der Kennungen und Art und Anzahl der Dateien abhängig.

Für die Gesamtlaufzeit einer Sicherung einschließlich Schreiben auf Band kann mit einer Laufzeitverbesserung gegenüber HSMS V7.0 von 10 bis 20% gerechnet werden (unter den Randbedingungen: viele Kennungen mit vielen Dateien, durchschnittliche Dateigröße ca. 10 Mbyte, Sicherung mit parallelen Läufen (Runs)).

Mit HSMS und den kleinen Auftragspaketen kann auch die Sicherung einer Kennung parallelisiert werden. Damit kann der Gesamtdatendurchsatz annähernd verdoppelt werden. Der größte Leistungsgewinn wird schon mit 2 parallellen Läufen (Runs) erreicht.

Übersicht über die Performance-Maßnahmen

Folgende Maßnahmen wurden in der logischen Datensicherung zur Unterstützung der kontinuierlichen Leistungssteigerung der Peripherie getroffen:

- HSMS/ARCHIVE
  - Unterstützung „großer Bandblöcke“
  - Nutzung von Ein-/Ausgaben bis zu 160 KB für Platten-Ein-/Ausgaben
  - parallele Auftragspakete
  - asynchrone, parallele Ein-/Ausgaben (ermöglicht die Nutzung von PAV/RSC)
  - HSMS/ARCHIVE V9.0:
    - Verringerung der Anzahl nötiger Ein-/Ausgaben durch größere interne Transferlängen
    - Performance-Verbesserung für Dateien kleiner und mittlerer Größe
- BS2000/OSD-BC
  - mehrere, parallele Ein-/Ausgaben pro Volume
    (PAV und DPAV auf S-Servern, RSC auf SX- und SQ-Servern, siehe Seite 69)
  - BS2000/OSD-BC V8.0:
    Optimierung der internen Transferlängen bei Platten-Ein-/Ausgaben

Vergleich zur Vorversion

Mit HSMS/ARCHIVE V9.0 (BS2000/OSD-BC V8.0) ergeben sich bei Vergleichsmessungen gegenüber HSMS/ARCHIVE V8.0 (BS2000/OSD-BC V7.0) folgende Verbesserungen:

- Soweit nicht die Bandseite begrenzt, kann sich bei „großen“ Dateien der Durchsatz um bis zu 10% verbessern. Auch der CPU-Bedarf kann sich um bis zu 10% verringern.
- Bei „kleinen“ Dateien kann sich der Durchsatz um bis zu 10% verbessern. Auch der CPU-Bedarf kann sich um bis zu 15% verringern.
- Die I/O-Rate verringert sich erheblich, in manchen Fällen um bis zu 50%.

5.2 Physikalische Datensicherung mit FDDRL

Mit FDDRL werden Volumes auf Basis der physikalischen Blockstruktur und demnach ohne Katalogzugriff gesichert. FDDRL unterstützt Public-Volumes (SF- und SM-Pubsets), Privatplatten und – unter besonderen Bedingungen – Volumes von Fremdsystemen.
Zur Bearbeitung mit FDDRL muss das Pubset mit `/EXPORT-PUBSET` exportiert werden.

Parallelität

Mit FDDRL können mehrere Volumes parallel und unabhängig voneinander unter eigenen Tasks (FDDRL-Subtasks) auf eine entsprechende Anzahl (ggf. virtueller) Bänder gesichert bzw. davon rekonstruiert werden. Der Grad der Parallelisierung wird durch den FDDRL-Parameter `TASK-LIMIT` vorgegeben.

Mit FDDRL werden außerdem beim Lesen von der Platte (DUMP) bzw. beim Schreiben auf die Platte (RELOAD) asynchrone Ein-/Ausgaben erzeugt.
Diese Ein-/Ausgaben werden parallel ausgeführt, wenn die Funktion Parallel Access Volume (PAV) des Plattenspeichersystems zusammen mit einem geeignetem RAID-Level genutzt wird (siehe Seite 69).

RUN-PRIORITY

Die Task-Priorität für die FDDRL-Subtasks wird mit dem FDDRL-Parameter `RUN-PRIORITY` im Rahmen der Job-Klasse angegeben. Damit kann die Priorität der FDDRL-Verarbeitung gesteuert und der Durchsatz beeinflusst werden:

- Ziel: ein FDDRL-Lauf soll während eines gering belasteten BS2000-Betriebs möglichst rasch und ohne Rücksicht auf das Antwortzeitverhalten durchgeführt werden.

  In diesem Fall sollte der Parameter `TASK-LIMIT` den Wert der verfügbaren Bandgeräte haben (maximal 16), um durch den hohen Grad der Parallelisierung einen guten Durchsatz zu erreichen. Der Parameter `RUN-PRIORITY` sollte „hoch“ eingestellt werden.

- Ziel: ein FDDRL-Lauf soll während eines normalen BS2000-Betriebs ohne Beeinträchtigung der Performance der Hauptanwendung durchgeführt werden.

  In diesem Fall sollte der Parameter `TASK-LIMIT` mit Rücksicht auf die übrigen Anwendungen relativ niedrig eingestellt werden. Bei mehreren parallelen Läufen muss mit einer erkennbaren Verschlechterung des Antwortzeitverhaltens der übrigen Anwendungen rechnen.
  Der Parameter `RUN-PRIORITY` sollte „niedrig“ eingestellt werden.

Große Bandblöcke

Um der kontinuierlichen Entwicklung neuer Bandspeichersysteme Rechnung zu tragen, arbeitet FDDRL standardmäßig mit maximal großen Platten-Ein-/Ausgaben und „großen Bandblöcken“ in der gleichen Größe (für FBA z.B. 160 KB).

Das frühere V13-Format, bei dem eine Platten-Ein-/Ausgabe mit 56 KB in zwei kleine Bandblöcke von 28 KB aufgeteilt wird, kann optional gewählt werden.

Mit diesen „großen Bandblöcken“ werden bei Bandverarbeitung deutliche Leistungsverbesserungen (bis Faktor 2) gegenüber den bisherigen „Standard-Bandblöcken“ erreicht.

Multiplexing

Wegen der hohen Kapazität der neuen Magnetbandkassetten verwendet FDDRL ein neues Bandformat, bei dem mehrere Platten auf einem Band (mit Folgebändern) nach Bedarf gesichert werden (z.B. alle Platten eines Pubsets). Dies kann weiterhin mit parallelem Betrieb von mehreren Bandgeräten für einen Auftrag kombiniert werden.

Wegen der sehr hohen Durchsatzraten der neuen Magnetbandgeräte (insbesondere LTO-Geräte und ETERNUS CS (CentricStor)) wird auch ein Multiplexing zwischen Band und Platte genutzt:
für ein Band wird abwechselnd und überlappend von bis zu vier Platten gelesen (DUMP) bzw. geschrieben (RELOAD).

Multiplexing ist vor allem dann sinnvoll, wenn die Plattenverarbeitung langsamer als die Bandverarbeitung ist. In solchen Fällen kann der Durchsatz mit dem Multiplexing annähernd verdoppelt werden (bei Multiplexing-Faktor zwei). Die Verbesserungen sind geringer bei ähnlicher Geschwindigkeit der Platten- und Bandverarbeitung oder wenn ihre Grenzen mit zwei parallelen Volumes erreicht werden.

In FDDRL V17.0 wird bei der Sicherungseinheit „Disk-Set“ der Multiplexing-Faktor vier unterstützt. Dadurch können auch Konfigurationen performant bedient werden, bei denen der Durchsatz des Bandgerätes durch die Sicherung von nur zwei Platten nicht erreicht wird (z.B. LTO-4). Bei Multiplexing-Faktor vier kann so der Gesamtdurchsatz im Idealfall nochmals verdoppelt werden.

Übersicht über die Performance-Maßnahmen

Folgende Maßnahmen wurden in der physikalischen Datensicherung zur Unterstützung der kontinuierlichen Leistungssteigerung der Peripherie getroffen:

- FDDRL
  - Unterstützung „großer Bandblöcke“
  - Nutzung von Ein-/Ausgaben bis zu 160 KB bei der Plattenverarbeitung
  - asynchrone, parallele Ein-/Ausgaben (ermöglicht die Nutzung von PAV/RSC)
  - Multiplexing
    (ab FDDRL V17.0 können vier Volumes parallel auf ein Band gesichert werden)
  - Optimierung der Datenverwaltung in FDDRL V17.0
- BS2000/OSD-BC
  - mehrere, parallele Ein-/Ausgaben pro Volume
    (PAV und DPAV auf S-Servern, RSC auf SX- und SQ-Servern, siehe Seite 69)
  - BS2000/OSD-BC V8.0:
    Optimierung der internen Transferlängen bei Platten-Ein-/Ausgaben

5.3 Performance-Maßnahmen im Sicherungsbetrieb (HSMS)

Dargestellt werden verschiedene Möglichkeiten, die vom Kunden verwendet werden können um eine bessere Performance bei der logischen Datensicherung mit HSMS/ARCHIVE zu erzielen. Hauptziel ist die Verkürzung der Sicherungszeit.

Die vorgestellten Maßnahmen können einzeln und unabhängig voneinander durchgeführt werden. Die Maßnahmen wirken sich in allen Situationen nur vorteilhaft aus. Eine Situationsanalyse ist nicht nötig.

Eine genaue Angabe des Performance-Gewinns jeder Maßnahme ist nicht möglich. Rahmensituation und Nutzungsart (z.B. Dateigröße) sind zu berücksichtigen. Alle Maßnahmen (mit Ausnahme von 4.) können mit einem regulären oder zeitkritischen Sicherungsauftrag einfach getestet werden. Der Performance-Gewinn ergibt sich aus dem Vergleich der Sicherungszeiten mit und ohne Maßnahme.

Die Maßnahmen werden vorrangig betrachtet in ihrer Auswirkung auf den Sicherungsbetrieb. Die Störung von parallel betriebenen Anwendungen kann i.d.R. vernachlässigt werden. Bei einigen Maßnahmen (z.B. 3. und 5.) wird die Sicherungszeit verkürzt bei unveränderter Gesamtzahl der Ein-/Ausgaben der Sicherung. Dadurch entsteht eine erhöhte Ein-/Ausgabe-Last pro Zeiteinheit.

1. Sicherungsumfang beschränken durch Dateiselektion und Differenzverfahren

   Die Verwendung der Parameter `FROM-/EXCEPT-FILE` (Positiv- und Negativangabe mit Teilqualifizierung) wird empfohlen.

   Eine Maximum-Backup-Class kann vorgegeben werden: nur Dateien mit einer Backup-Klasse kleiner oder gleich der angegebenen Backup-Klasse werden gesichert (als Dateiattribut mit Voreinstellung Backup-Class = A)

   Temporäre Dateien und Paging-Dateien werden nie mitgesichert.

   Management-Klassen in SM-Pubsets (frei vergebbares Dateiattribut für Gruppenbildung in SM-Pubsets) können zur Dateiselektion bei Backup und Migration benutzt werden

   Es steht zur Wahl, ob auch migrierte Dateien mitgesichert werden sollen (Backup-Operand `SAVE-DATA`). Standardmäßig werden nur die Katalogeinträge von migrierten Dateien mitgesichert.

   Bei Differenzsicherungen zwischen den periodischen Vollsicherungen kann zwischen zwei Verfahren gewählt werden:

   - MODIFIED: Dateien nur sichern, wenn diese im Archiv noch nicht vorhanden sind
   - BY-CATALOG-MODIFICATION: Dateien sichern, falls diese erst nach einem vorgegebenem Datum bzw. nach dem Datum des letzten Backup für das gleiche Archiv geändert wurden

2. Archive bzw. Archiv-Verzeichnisse sinnvoll aufteilen
   - Dezentrale Organisation (Archive pro Pubset) auch für große SF-Pubsets
   - Getrennte Archive für Backup und Langzeitsicherung
3. Sicherungszeit verkürzen durch Parallelbetrieb (erhöhte Ein/Ausgabe-Last!)

   Mehrere HSMS-Aufträge (für verschiedene Archive) gleichzeitig ausführen. Die Maximalzahl paralleler Aufträge kann durch die HSMS-Anweisung `//MODIFY-HSMS-PARAMETERS NUMBER-OF-SUBTASKS=` eingestellt werden.

   Es können pro Auftrag (Angabe von `PARALLEL-RUNS` entweder im Auftrag oder als Archiv-Attribut) mehrere Bandgeräte durch ARCHIVE-Subtasking genutzt werden.

   Several-SVID-Format zum Fortschreiben von Sicherungsbändern (CONTINUE) nutzen. Dies ist praktisch eine Voraussetzung für einen Parallelbetrieb wegen des sonst hohen Bandverbrauchs.

   Die interne Geräte-Reservierung (bei HSMS-Betrieb) und die Dateisicherung auf Band erfolgen in unabhängigen ARCHIVE-Subtasks, d.h. ein nicht oder nicht gleich verfügbares Gerät hält das Sichern mit den anderen Geräten nicht auf!

   Mit HSMS generiert die ARCHIVE-Maintask bei Verwendung des Parameters `PARALLEL-RUNS` die Auftragspakete für zu sichernde Dateien und vergibt diese an die nächste freie Subtask zum Sichern. Von dieser erfolgt die Rückmeldung an die Maintask zum Eintrag der nun gesicherten Dateien ins Archivverzeichnis und in die Report-Datei. Kleinere Pakete sorgen damit für eine parallele Abwicklung auch beim Sichern von nur einer Kennung und einem Katalog, sowie für eine gleichmäßigere Auslastung zwischen den Subtasks und eine bessere Überlappung der Subtasks mit der Maintask. Der Nachlauf nach dem Schließen der Bänder wird verkürzt.

   Durch Verbesserung des Parallelbetriebes wird die Laufzeit verkürzt, die Anzahl der Ein-/Ausgaben pro Sekunde wird erhöht.

   Bei Einsatz von vielen Bandgeräten (z.B. mit ETERNUS CS (CentricStor) VTA) können diese vermehrt parallel genutzt werden. HSMS/ARCHIVE sorgt für eine effiziente Nutzung dieser Geräte.
4. Durchsatz von Platte und Band erhöhen

   Bei Platten ist das FBA-Format dem CKD-Format vorzuziehen. ARCHIVE reduziert für eine gute Performance die Gesamtzahl der Platten-Ein-/Ausgaben durch möglichst große Ein-/Ausgabeblöcke. Die maximale Blockgröße für das FBA-Format beträgt 160 KB, für das CKD-Format nur 72 KB.

   Sowohl für Plattenspeichersysteme als auch für Bandsysteme ist der Anschluss über Kanal Typ FC dem Anschluss über Kanal Typ S vorzuziehen. Voraussetzung: FBA-Formatierung der Platten, weil der Kanal Typ FC höhere Datenraten erlaubt.

Um die Zahl der Band-Ein-/Ausgaben zu reduzieren, wird der Betrieb mit großen Bandblöcken (256 KB statt bisher 32 KB) empfohlen
(Angabe `BLOCKING-FACTOR = *MAX` in Anweisungen, als Archivattribut oder als globaler ARCHIVE-Parameter `MBK-SIZE = *BIG`)

In ARCHIVE wird stets die Hardware-Komprimierung von/in MBK-Geräten genutzt. Wahlweise kann die Software-Komprimierung für DMS-Sicherung auf Platte genutzt werden. Die Komprimierung als Software-Funktion ist allerdings nachteilig für die CPU-Performance.

Der Übergang von CKD- nach FBA-Formatierung ist schon bei Anschluss über Kanal Typ S sinnvoll.

Der Parallelbetrieb wird in der Praxis durch die Kanalausstattung begrenzt, weniger durch die CPU-Leistung.

HSMS/ARCHIVE belastet die Plattenseite zusätzlich durch Katalogzugriffe und den Verschnitt von kleinen Dateien.

5. Multiplexing (Erzeugen paralleler Datenströme)

   Im BS2000-Sicherungsbetrieb können mit HSMS/ARCHIVE und der Funktion PAV (Parallel Access Volume) mehrere Ein-/Ausgaben auf Platte parallel gestartet werden. Auf diese Weise kann ein Multiplexing der Datenströme zwischen Band und Platte erreicht werden.

6. Ausfallzeit für den Online-Betrieb verkürzen bei unveränderter Sicherungszeit (Wiederanlauf der Anwendung vor der eigentlichen Sicherung!)

   Voraussetzung:
   Nutzung von TimeFinder BCV- oder Clone-Spiegel im Symmetrix-Plattenspeichersystem bzw. SnapView Clone-Spiegel im FibreCAT CX-Plattenspeichersystem.

   Mit der Funktion CCOPY ist der Anwendungs-Restart schon nach der Abtrennphase der Spiegelplatte möglich, während die Sicherung noch läuft. Dabei wird die Dateisicherung auch auf der Spiegelplatte lokal ausgeführt.
   Dies erlaubt die Lasttrennung zwischen der Anwendung auf der Originalplatte und der Sicherung auf der Spiegelplatte, so dass der Anwendungsbetrieb nicht durch die Ein-/Ausgaben der Sicherung gestört wird.

   Bei Sicherung mit impliziter Erstellung einer Bandkopie (Schattenarchiv) ist der Anwendungs-Restart schon nach der Sicherung und vor dem Kopiervorgang möglich.

   Eine Auftrags-Jobvariable zeigt in diesen Fällen den Status für den Anwendungs-Restart vor Abschluss des Auftrags an.

7. Performance der Katalogzugriffe bei DMS-Sicherungen

   Es ist sinnvoll die (Voreinstellung zur) Katalogpufferung pro Pubset von 6 auf 32 Puffer zu erhöhen mit dem Systemparameter `BMTNUM`, siehe Seite 363.

   Bei Shared-Pubset-Betrieb werden normale Sicherungsaufträge HSMS-intern zur Master-Seite geschickt, um damit die schnelleren lokalen Katalogzugriffe ohne MSCF-Verkehr zu nutzen.

   Sicherungsaufträge mit CCOPY von BCVs oder Clones werden auch im Shared-Pubset-Betrieb stets lokal ausgeführt, weil die Katalogzugriffe lokal auf den abgetrennten BCVs oder Clones erfolgen. Dies erlaubt eine Trennung der Ein-/Ausgabe-Last (z.B. mit zwei Systemen für Anwendung und für Sicherung)

8. Performance der ISAM-Zugriffe auf Archiv-Verzeichnis und andere HSMS-Metadateien

   Die systemweiten ISAM-Pools sollten zur Reduktion der physikalischen Ein-/Ausgaben durch ISAM allgemein vergrößert werden von der Standardeinstellung 512 PAM-Pages auf 8192 oder mehr PAM-Pages (ISAM-Parameter `GLBDFPS`).

   Beim Sichern sehr vieler Dateien sollten, um einen kurzen Nachlauf zu erzielen, Summary-Reports (nur bei Fehlern erfolgen dateiweise Einträge) statt Full-Reports (Einträge für alle Dateien) verwendet werden.

9. Interne Schnellpfade zum Kopieren von ganzen Sicherungs-Versionen und -Dateien

   Verwenden des Schnellpfades für `COPY-SAVE-FILE` ohne Dateiauswahl, d.h. sequenzielles Lesen vom Eingabeband, ohne vorher eine Dateiliste aus dem Input-Directory abzuleiten.

   Ein deutlicher Performance-Gewinn wird erkennbar im Vorlauf (vor der Bandmontage) und damit auch in der Gesamtsicherungszeit, z.B. beim Kopieren ins Schattenarchiv.

10. Datenbank-Sicherungen im laufenden Datenbank-Betrieb

    Die Sicherung von Dateien, die gesichert werden können, aber zum Schreiben eröffnet sind, ist mit der Backup-Option `ONLINE-SAVE = *YES` möglich, z.B. für UDS-Datenbanken mit Logfiles und für Oracle Datenbank-Dateien oder einzelne Tablespaces.

    Die Sicherung für SESAM-Datenbanken durch SESAM/SQL über die HSMS-Programmschnittstelle erfolgt in gleicher Weise, auch in Kombination mit CCOPY von BCVs oder Clones. Dies führt zu minimalen Ruhephasen im Datenbank-Betrieb.

5.4 Komponenten bei der Datensicherung

Performance-relevante Komponenten bei der lokalen Datensicherung sind:

- Software: HSMS/ARCHIVE bzw. FDDRL
- BS2000-CPU
- Bandspeichersystem einschließlich Anschluss an den Server
- Plattenspeichersystem einschließlich Anschluss an den Server

In diesem Abschnitt wird die Leistung einiger Teilkomponenten betrachtet. Daraus lassen sich dann näherungsweise die zu erwartenden Durchsatzraten bei der Datensicherung bzw. -rekonstruktion in konkreten Konfigurationen abschätzen.

Die Sicherungsleistung wird vom kleinsten Durchsatzwert der beteiligten Teilkomponenten bestimmt.

Die angegebenen Durchsatzraten beziehen sich auf eine Task während der eigentlichen Sicherungsphase, also ohne Montieren des Bandes, ohne Erstellen der Report-Dateien oder dem Starten und Beenden der Programme.

Die Messergebnisse in diesem Abschnitt setzen günstige Bedingungen voraus, z.B. keine parallele Last auf der Messkonfiguration, ausreichend CPU-Leistung.

5.4.1 BS2000-CPU

Bei einer lokalen Datensicherung sind für den CPU-Bedarf in BS2000/OSD näherungsweise folgende Werte anzusetzen:

Datensicherung mit		**CPU-Bedarf (RPF pro Mbyte/s)**			
		S-Server		**SX-/SQ-Server**	
HSMS	**Dateigrößen**	**Save**	**Restore**	**Save**	**Restore**
	Groß (1.000 Mbyte)	1,3	1,3	0,7	0,7
	Mittel (10 Mbyte)	1,3	1,4	0,7	0,8
	Klein (1 Mbyte)	1,5	2,3	0,8	1,5
FDDRL		**Dump**	**Reload**	**Dump**	**Reload**
		< 0,2	< 0,2	< 0,1	< 0,1

Auf SX- und SQ-Servern werden alle Ein-/Ausgaben über I/O-Prozessoren geleitet.
Für I/O-Prozessoren sind, unabhängig von der Dateigröße, bei der Datensicherung folgende Auslastungswerte anzusetzen:

- HSMS:
  - Save: 0,9% CPU-Leistung pro Mbyte/s
  - Restore: 0,7% CPU-Leistung pro Mbyte/s
- FDDRL:
  - Dump: 0,8% CPU-Leistung pro Mbyte/s
  - Reload: 0,7% CPU-Leistung pro Mbyte/s

Insbesondere auf Multiprozessor-Systemen ist zu beachten, dass die für eine Sicherungstask notwendige CPU-Leistung von nur einer BS2000-CPU erbracht werden muss.

5.4.2 Anschluss an den Server

Für den Anschluss an den Server gelten die theoretischen Durchsatzleistungen:

- Kanal Typ S (S- und SX-Server): 17 Mbyte/s
- Kanal Typ FC (S-Server): 1 Gbit/s bzw.
  FC-Anschluss (SX- und SQ-Server): 1 bis 4 Gbit/s

Der Anschluss hat großen Einfluss auf die Leistung der Band- und Plattenspeichersysteme. Durch Einsatz des Kanals Typ FC bzw. des FC-Anschlusses ist eine wesentliche Durchsatzsteigerung möglich. Die volle Leistung der neueren Band- und Plattenspeichersysteme kann nur mit Kanälen Typ FC bzw. FC-Anschluss genutzt werden, Kanäle Typ S sind dazu nicht mehr geeignet.
Abhängig von der Leistung der Peripheriegeräte liegen die Verbesserungen mit Kanal Typ FC bzw. FC-Anschluss bei der Datensicherung bei Faktor 4 und besser.

Plattenspeichersysteme sind normalerweise über mehrere Pfade angeschlossen. Wenn im Plattenspeichersystem die Möglichkeiten der Parallelisierung (geeignete RAID-Gruppen, PAV, Multiplexing) genutzt werden, dann können bei den Durchsatz-orientierten Lasten der Datensicherung die Anschlüsse sehr hoch ausgelastet werden.

Schnelle Bandgeräte sollten an schnellen Kanälen Typ FC bzw. FC-Anschluss angeschlossen werden. Diese sollten nicht gemeinsam mit den Plattenspeichersystemen genutzt werden. Die Kanäle der S-Server werden bei der Datensicherung weitgehend ausgelastet. Bei SX-Servern wird für einen optimalen Durchsatz der Einsatz von FC-Controllern mit mehr als 1 Gbit/s empfohlen.

5.4.3 Bandspeichersysteme

Virtuelles Archivsystem ETERNUS CS (CentricStor)

Mit ETERNUS CS (CentricStor) wird einem realen Archivsystem mit den physikalischen Laufwerken und Kassetten ein virtuelles Archivsystem vorgelagert. Während die Datensicherungsanwendung auf dem Server weiterhin davon ausgeht, mit MBK-Laufwerken zu arbeiten, nimmt das virtuelle Archivsystem eine Zwischenspeicherung auf Magnetplatte (Tape Volume Cache) vor. Dadurch kann die Parallelität bei der Datensicherung auch ohne Vervielfachung der Anzahl realer MBK-Laufwerke erhöht werden. Erst nach der vollständigen Übertragung der Daten auf das virtuelle MBK-Gerät und nach dessen Entladen werden die Daten physikalisch auf MBK gespeichert. Mit diesen Vorteilen wird ETERNUS CS (CentricStor) für den Nearline-Betrieb im BS2000-Umfeld dringend empfohlen.
(Die im Folgenden angegebenen Performancedaten beziehen sich auf CentricStor V4.0.)

MBK-Archivsysteme Scalar mit LTO-Technologie

Parallel oder alternativ zu ETERNUS CS (CentricStor) können die LTO-Geräte der realen MBK-Archivsysteme Scalar der Fa. Quantum Corp. direkt an den BS2000/OSD-Server angeschlossen werden. Informationen zu diesen MBK-Archivsystemen finden Sie im Handbuch „ROBAR“ ([25]) und im Internet unter
http://www.quantum.com/DE/index.aspx --> Bandbibliotheken.

Im Unterschied zum ETERNUS CS (CentricStor) ist die Parallelität durch die Anzahl der MBK-Laufwerke begrenzt.

MBK-Archivsysteme

Für eine Bandautomatisierung steht an den neueren SX-Servern und am Business Server SQ100 optional ein MBK-Archisvsystem mit bis zu 24 Datenkassetten in LTO-Technologie zur Verfügung:

- SX100-C/-D, SX140, SX150, SX160: MBK-Wechsler FibreCAT TX24
- SQ100: MBK-Library ETERNUS LT40 (früher: FibreCAT TX24 S2)

Durchsatz und Komprimierung bei LTO-Laufwerken

Die folgenden Ausführungen beziehen sich auf den Direktanschluss von LTO-Geräten an den BS2000/OSD-Server (ohne ETERNUS CS (CentricStor)).

Die vom Server (z.B. einem BS2000-System) geschriebenen Daten werden zunächst in den Cache des LTO-Gerätes übertragen. Hier werden sie soweit möglich vom LTO-Gerät komprimiert. Die komprimierten Daten werden dann auf das physikalische Band im LTO-Laufwerk geschrieben. Beim Lesen wird die analoge Vorgehensweise angewandt.

Für LTO-Geräte gelten folgende Leistungswerte:

Gerätetyp	Maximaler Durchsatz	Kapazität
LTO-2	40 Mbyte/s	200 Gbyte
LTO-3	80 Mbyte/s	400 Gbyte
LTO-4 (S- und SQ-Server)	120 Mbyte/s	800 Gbyte

Diese Leistungswerte beziehen sich auf das Laufwerk bzw. die physikalischen Kassetten.

Davon zu unterscheiden sind folgende Daten:

Gerätetyp	Compressed Data Rate	Compressed Capacity
LTO-2	80 Mbyte/s	400 Gbyte
LTO-3	160 Mbyte/s	800 Gbyte
LTO-4 (S- und SQ-Server)	240 Mbyte/s	1.600 Gbyte

Diese Daten beziehen sich auf den Datentransfer zwischen Server und LTO-Gerät, also noch vor der Komprimierung (Schreiben), bzw. nach der Dekomprimierung (Lesen). Dabei wird ein Komprimierungsfaktor 2 angenommen. In BS2000/OSD liegen typische Komprimierungsfaktoren bei 2 bis 3. Damit ergibt sich für BS2000/OSD folgender Durchsatz:

- LTO-2: 70 bis über 100 Mbyte/s
- LTO-3: 160 bis über 240 Mbyte/s
- LTO-4: 240 bis über 360 Mbyte/s

Ein solcher Durchsatz ist in BS2000/OSD nur bedingt möglich und auch nur selten nötig. Bei S-Servern wird der Durchsatz bei LTO-3 durch den 1 Gbit/s Kanal Typ FC begrenzt, bei SX-Servern durch die noch nicht optimierte Band-IO. Damit ergeben sich auf S-Servern mit LTO-4 weder beim Durchsatz noch beim Streamingverhalten große Änderungen. Bei SQ-Servern zeigen sich hier erheblich bessere Werte.

LTO-4-Laufwerke unterstützen hardwareseitig die „Tape Encryption“. Die Datenrate verringert sich bei eingeschalteter Tape Encryption nach Herstellerangaben lediglich um ca. 1%.

Streaming-Grenze bei LTO-Laufwerken

LTO-Geräte arbeiten am besten, wenn die Daten möglichst gleichmäßig mit dem maximalen Durchsatz zum Band übertragen werden.

Wenn vom Server (unter Berücksichtigung der Komprimierungsrate) mit einer Datenrate geschrieben wird, die unterhalb des maximalen Durchsatzes liegt, dann passt sich das LTO-Gerät dieser niedrigeren Datenrate an („Rate Adaption“). Damit können Lastschwankungen ausgeglichen werden. Die untere Grenze für die „Rate Adaption“ ist die „Streaming-Grenze“ des LTO-Geräts. Die Streaming-Grenze ist Geräte- und Hersteller-abhängig und liegt bei etwa

- 15 Mbyte/s für LTO-2
- 30 Mbyte/s für LTO-3 und LTO-4

Wenn die Datenrate unter die Streaming-Grenze fällt, dann kommt es zum „Start-/Stopp-Betrieb“. Band und Laufwerk unterliegen dabei erhöhten mechanischen Belastungen, die die Lebensdauer verkürzen können. Ein lang andauernder Start-/Stopp-Betrieb sollte deshalb vermieden werden. Kurzzeitiger Start-/Stopp-Betrieb beim Montieren bzw. Demontieren ist nicht zu vermeiden.

Die richtige Kassettenwahl entscheidet über Qualität und Langlebigkeit: Kassetten und Laufwerk müssen zusammenpassen. Es wird dringend empfohlen, nur qualifizierte Kassetten mit der Kennzeichnung „Preferred Quality“ zu verwenden.

Bei einem Komprimierungsfaktor 2 müssen vom Server also bei LTO-2 30 Mbyte/s, bei LTO-3 und LTO-4 60 Mbyte/s transferiert werden um die Streaming-Grenze zu überschreiten. Wenn dies bei langsamen Servern nicht erreicht wird, dann kann, um mögliche Bandmaterialschäden zu vermeiden, in BS2000/OSD mit dem Dienstprogramm IORM die Komprimierung auf dem LTO-Laufwerk ausgeschaltet werden. Mit IORM kann die Komprimierung auch dynamisch, in Abhängigkeit von der aktuellen Transferrate, ein- und ausgeschaltet werden. Bei ausgeschalteter Komprimierung ist der Durchsatz von BS2000/OSD zum LTO-Gerät und weiter zum Laufwerk gleich.
Auf SX100-Servern ist die Komprimierung standardmäßig ausgeschaltet.

Leistung der Bandspeichersysteme

Bei der Datensicherung werden die Daten auf ein oder mehrere Bandspeichersysteme geschrieben, bei der Datenrekonstruktion entsprechend gelesen.
Dieser Abschnitt betrachtet die Leistung von Bandspeichersystemen isoliert, also ohne die weiteren Komponenten für die Datensicherung.

Die Leistung neuerer Bandspeichersysteme kann erst mit Kanälen Typ FC bzw. FC-Anschluss voll genutzt werden. Wenn die Bandgeräte über Kanal Typ S angeschlossen werden, dann kann ein Durchsatz von maximal 15 Mbyte/s erreicht werden.

Mit BS2000/OSD kann durch die „großen Bandblöcke“ (256 KB statt 32 KB pro Ein-/Ausgabe) die Leistung bis zum Faktor 2 gesteigert werden.

Die folgenden Tabellen zeigen den möglichen Durchsatz verschiedener Bandspeichersysteme. Die Last entspricht einer Datensicherung mit HSMS/ARCHIVE bzw. FDDRL mit großen Bandblöcken. Die Ein-/Ausgaben werden nur vom BS2000-Hauptspeicher (nicht von Platte) zum MBK-Gerät durchgeführt.

Der Durchsatz ist jeweils für schwer komprimierbare Daten (Komprimierungsfaktor 1) und für normal komprimierbare Daten (Faktor 2 - 3) angegeben.

S190-Server, Anschluss über Kanal Typ FC (1 Gbit/s):

		Durchsatz (Mbyte/s)			
Komprimierungsfaktor		1		2 - 3	
MBK-System	**Geräte**	Schreiben	Lesen	Schreiben	Lesen
Scalar 10K	LTO-3	80	80	90	95
Scalar i2000	LTO-3	80	60	80	60
Scalar i500	LTO-3	80	80	95	95
ETERNUS CS (CentricStor)	VTA	65	55	90	70

Mit fast 100 Mbyte/s wird meist die Grenze des Kanals Typ FC erreicht.

Leistung mit Kanaladapter 3971

Ein Bandgerät 3591 mit Kanaladapter 3971 erreicht über einen Kanal Typ S an einem S-Server einen Durchsatz von etwa 12 Mbyte/s. Wenn ein Bandspeichersystem 3591 mit zwei MBKs über zwei Kanäle Typ S betrieben wird, kann der Gesamtdurchsatz auf 21 Mbyte/s gesteigert werden.

SX160-Server, FC-Anschluss (2 Gbit/s):

		Durchsatz (Mbyte/s)			
Komprimierungsfaktor		1		2 - 3	
MBK-System	**Geräte**	Schreiben	Lesen	Schreiben	Lesen
Scalar 10K	LTO-3	75	65	80	75
Scalar i2K	LTO-3	75	50	80	50
Scalar i500	LTO-3	80	70	80	75
TX24	LTO-3	55	60	60	70
ETERNUS CS (CentricStor)	VTA	65	50	90	70

SQ100-Server, FC-Anschluss (4 Gbit/s):

		Durchsatz (Mbyte/s)			
Komprimierungsfaktor		1		2 - 3	
MBK-System	**Geräte**	Schreiben	Lesen	Schreiben	Lesen
ETERNUS CS (CentricStor)	VTA	200	200	200	200

5.4.4 Plattenspeichersysteme

Eigenschaften der Datensicherungslast

Bei der Datensicherung werden die Daten sequenziell gelesen bzw. geschrieben. Mit HSMS/ARCHIVE bzw. FDDRL erfolgt dies in mehreren parallelen, asynchronen Datenströmen von und zum Plattenspeichersystem. Normalerweise werden sehr große Datenmengen übertragen. Die Caches der Plattenspeichersysteme kommen dabei an ihre Grenzen. Deshalb muss mit Read-Ahead-Strategien von den physikalischen Platten gelesen bzw. mit Delayed Fast Writes auf die physikalischen Platten geschrieben werden. Für den erreichbaren Durchsatz ist deshalb die Leistung der physikalischen Platten und der RAID-Gruppen entscheidend. Die heutigen Plattenspeichersysteme erreichen bei einer Datensicherungslast auch mit Read-Ahead bzw. Delayed Fast Write einen sehr guten Durchsatz.

Leistung von Plattenspeichersystemen

Bei der Datensicherung werden die Daten von ein oder mehreren Plattenspeichersystemen gelesen, bei der Datenrekonstruktion entsprechend geschrieben.
Dieser Abschnitt betrachtet die Leistung von Plattenspeichersystemen isoliert, also ohne die weiteren Komponenten für die Datensicherung.

Die Leistung neuerer Plattenspeichersysteme kann erst mit Kanälen Typ FC bzw. FC-Anschluss voll genutzt werden.
Wenn die Plattenspeichersysteme über Kanal Typ S angeschlossen werden, dann kann ein Durchsatz von maximal 8 - 12 Mbyte/s erreicht werden.

Um hohe Durchsätze zu erreichen, müssen neben einem mehrpfadigen Anschluss über Kanal Typ FC geeignete RAID-Level vorgesehen werden (siehe Abschnitt „Eigenschaften von Plattenspeichersystemen“ auf Seite 57). Dabei bieten die RAID-Level RAID1/0, RAID5 oder RAID6 für die Datensicherung den besten Durchsatz.
RAID1 ist insbesondere bei Lasten mit mittlerer bis hoher Parallelität wenig geeignet um einen hohen Durchsatz zu erzielen.

Die folgenden Tabellen zeigen den möglichen Durchsatz mit verschiedenen Plattenspeichersystemen und Einstellungen. Die Messwerte gelten zum einen für den optimalen Fall mit wenigen großen Dateien (1000 MByte). Sie zeigen auch die Durchsatzverringerung, wenn statt der optimalen sehr großen Dateien mittlere (10 MByte) oder kleine (1 MByte) Dateien gesichert werden.

Dabei wird das Lesen nur vom Plattenspeichersystem in den BS2000-Hauptspeicher ausgeführt, ohne das Schreiben auf Band. Das Plattenspeichersystem hat einen mehrpfadiger Anschluss über Kanal Typ FC bzw. FC-Anschluss.

S190-Server, Plattenspeichersystem DMX-3, Anschluss über Kanal Typ FC (1 Gbit/s, 4-pfadig)

RAID-Level	Durchsatz Lesen (in Mbyte/s)					
Dateigröße	1000 Mbyte		10 Mbyte		1 Mbyte	
PAV (1 Alias)	ohne PAV	mit PAV	ohne PAV	mit PAV	ohne PAV	mit PAV
RAID1	70	75	50	70	35	40
RAID1/0	75	140	70	130	60	90
RAID5	75	130	70	125	50	90

SX160-Server, Plattenspeichersystem DMX-3, FC-Anschluss (2 Gbit/s, 2-pfadig)

RAID-Level	Durchsatz Lesen (in Mbyte/s)		
Dateigröße	1000 Mbyte	10 Mbyte	1 Mbyte
RAID1	60	55	35
RAID1/0	115	110	70
RAID5	105	100	65

Bei der Datensicherung ergibt sich für RAID-Gruppen mit „data striping“ (RAID1/0, RAID5, RAID6) gegenüber RAID1 ein erheblich höherer Durchsatz. Er liegt bei großen Dateien meist deutlich über dem Durchsatz, der auf der Bandseite erreicht wird.

Der Durchsatzverlust bei mittleren Dateigrößen (10 MByte) ist gering. Erst unterhalb der Grenze von etwa 1 MByte wird er signifikant.

Der Durchsatz eines Plattenspeichersystems Symmetrix DMX-4 oder V-Max ist vergleichbar mit dem Durchsatz von DMX-3.

5.5 Messergebnisse

Aus der Vielzahl möglicher Konfigurationen wurden einige gemessen. Die Ergebnisse sind in den folgenden Tabellen dargestellt. Die Messungen (mit BS2000/OSD V7.0, HSMS V8.0B und FDDRL V16.0) erfolgten jeweils mit einem Task, Datenformat NK2, Plattenformat FBA, großen Bandblöcken und einem Datenmuster, das mit einem Faktor 2 - 3 von den Bandgeräten komprimiert wird.

Der Durchsatz nicht aufgeführter Konfigurationen kann abgeschätzt werden, wenn der Durchsatz der schwächsten beteiligten Komponente verwendet und ein kleiner Abschlag berücksichtigt wird. Bei HSMS/ARCHIVE muss bei der Sicherung vieler kleiner Dateien zusätzlich ein Abschlag vorgenommen werden.

5.5.1 HSMS/ARCHIVE

Sicherung auf einem S-Server

Die folgenden Durchsatzwerte wurden bei lokaler Sicherung mit HSMS/ARCHIVE bei einem HSMS-Task auf einem Server S190 erreicht:

Bandspeichersystem (LTO-3-Geräte)		Plattenspeichersystem DMX-3		Durchsatz (Mbyte/s)			
				ohne PAV		mit PAV (1 Alias)	
Typ	**Anschluss**	**Anschluss**	**RAID-L.**	**SAVE**	**RESTORE**	**SAVE**	**RESTORE**
Scalar 10K	Typ S	Typ S	RAID1	11	11	12	12
	Typ FC	Typ S	RAID1	11	11	12	12
	Typ S	Typ FC	RAID1	15	15	15	15
	Typ FC	Typ FC	RAID1	70	55	70	65
			RAID1/0	75	55	90	90
			RAID5	75	55	90	90
Scalar i500	Typ FC	Typ FC	RAID1	60	55	60	65
			RAID1/0	70	55	85	90
			RAID5	70	55	85	90
Scalar i2000	Typ FC	Typ FC	RAID1	50	55	50	60
			RAID1/0	60	55	80	60
			RAID5	60	55	80	60
ETERNUS CS (CentricStor)	Typ FC	Typ FC	RAID1	60	55	60	60
			RAID1/0	65	55	80	70
			RAID5	65	55	80	70

Sicherung auf einem SX-Server

Die folgenden Durchsatzwerte wurden auf auf einem Server SX160 erreicht:

Bandspeichersystem (LTO-3-Geräte)		Plattenspeichersystem DMX-3		Durchsatz (Mbyte/s)	
Typ	**Anschluss**	**Anschluss**	**RAID-L.**	**SAVE**	**RESTORE**
Scalar 10K	Typ FC	Typ FC	RAID1	50	60
			RAID1/0	60	60
			RAID5	60	60
Scalar i500	Typ FC	Typ FC	RAID1	45	65
			RAID1/0	65	70
			RAID5	65	70
ETERNUS CS (CentricStor)	Typ FC	Typ FC	RAID1	50	55
			RAID1/0	65	60
			RAID5	65	60
TX24	Typ FC	Typ FC	RAID1/0	55	60

5.5.2 FDDRL

Sicherung auf einem S-Server

Die folgenden Durchsatzwerte wurden bei Messungen mit FDDRL bei einem FDDRL-Task auf einem Server S190 erreicht:

Bandspeichersystem (LTO-3-Geräte)		Plattenspeichersystem DMX-3		Durchsatz (Mbyte/s)			
				ohne PAV		mit PAV (1 Alias)	
Typ	**Anschluss**	**Anschluss**	**RAID-L.**	**DUMP**	**RELOAD**	**DUMP**	**RELOAD**
Scalar 10K	Typ S	Typ S	RAID1	12	12	13	13
	Typ FC	Typ S	RAID1	12	12	13	13
	Typ S	Typ FC	RAID1	15	15	15	15
	Typ FC	Typ FC	RAID1	55	55	55	60
			RAID1/0	65	55	80	80
			RAID5	65	55	80	80
Scalar i500	Typ FC	Typ FC	RAID1	55	55	55	55
			RAID1/0	60	55	75	80
			RAID5	60	55	75	80
Scalar i2000	Typ FC	Typ FC	RAID1	55	55	55	55
			RAID1/0	60	55	80	55
			RAID5	60	55	80	55
ETERNUS CS (CentricStor)	Type FC	Type FC	RAID1	55	55	55	60
			RAID1/0	60	55	75	70
			RAID5	60	55	75	70

Detailmessungen auf einem S-Server

Basis der folgenden Aussagen sind Messungen auf einem Server S190.
Die Sicherung erfolgte zwischen einem Plattenspeichersystem DMX-3 (mit RAID1/0) und einem Bandspeichersystem Scalar i500 mit Laufwerken in LTO-3-Technologie.
Untersucht wurden zuerst die Band- bzw. die Plattenseite alleine,
dann eine komplette Datensicherung mit FDDRL V17.0 (BS2000/OSD V8.0).

Performance des Bandspeichersystems
(Transfer vom BS2000/OSD-Hauptspeicher zum Band):

- Bei nicht komprimierbaren Daten werden die Grenzen des LTO-3-Laufwerks von 80 Mbyte/s erreicht.
- Bei komprimierbaren Daten werden etwa 90 Mbyte/s erreicht. Der Durchsatz ist durch den Kanal Typ FC begrenzt, der bei 1 Gbit/s (100 Mbyte/s) liegt.

Performance des Plattenspeichersystems
(Lesen von Platte in den BS2000/OSD-Hauptspeicher):

- Die Multiplexing-Funktionen von FDDRL wirken perfekt.
  Beim parallelen Lesen von vier Volumes kann mit fast 300 Mbyte/s der vierfache Durchsatz gegenüber dem Lesen ohne Multiplexing (75 Mbyte/s) erreicht werden.
- Der Durchsatz auf der Plattenseite liegt deutlich über dem Durchsatz auf der Bandseite.

Performance der gesamten Datensicherung:

- Bei der verwendeten, sehr leistungsstarken Plattenseite wird auch ohne PAV und ohne Multiplexing ein sehr guter Durchsatz von 75 Mbyte/s (Funktion Dump) und 60 Mbyte/s (Funktion Reload) erreicht.
- Sowohl beim Einsatz von PAV als auch mit dem Multiplexing von FDDRL wird die Leistung bei etwa 90 Mbyte/s durch die Bandseite gebremst (Kanal Typ FC am S-Server). Der auf der Plattenseite mögliche, weit höhere Durchsatz kann nicht erreicht werden. Das Multiplexing mit vier Volumes kann bei „langsamen“ Platten (im Vergleich zur Bandseite) Verbesserungen bringen.
- Es ergeben sich Durchsatz-Verbesserungen von 10 - 20% gegenüber FDDRL V16.0 unter BS2000/OSD V7.0.

Sicherung auf einem SX-Server

Die folgenden Durchsatzwerte wurden auf auf einem Server SX160 erreicht:

Bandspeichersystem (LTO-3-Geräte)		Plattenspeichersystem DMX-3		Durchsatz (Mbyte/s)	
Typ	**Anschluss**	**Anschluss**	**RAID**	**DUMP**	**RELOAD**
Scalar 10K	Typ FC	Typ FC	RAID1	55	65
			RAID1/0	75	65
			RAID5	75	65
Scalar i500	Typ FC	Typ FC	RAID1	45	65
			RAID1/0	50	65
			RAID5	75	70
ETERNUS CS (CentricStor)	Typ FC	Typ FC	RAID1	55	65
			RAID1/0	75	70
			RAID5	75	70

5.6 Empfehlungen

Bei jeder Datensicherung sollte auf eine ausgewogene Leistung der verwendeten Band- und Plattenspeichersysteme geachtet werden. Dieser Abschnitt gibt Empfehlungen für einen möglichst hohen Durchsatz bei der Datensicherung.

Die allgemeinen Empfehlungen zur Geräteperipherie (siehe Kapitel „Leistungsverhalten der Peripherie“ auf Seite 57) gelten auch für die Datensicherung.

BS2000/OSD

- S-Server: „Dynamisches PAV“ (DPAV) verwenden
- Einsatz der Fibre Channel Anschlusstechnik (auf S-Servern Kanal Typ FC, nicht Kanal Typ S)

Bandspeichersysteme

- Einsatz von ETERNUS CS (CentricStor)
- Wenn schnelle LTO-Bandgeräte (ab LTO-3) direkt an den Server angeschlossen werden sollen:
  - Bandmaterial: Nur qualifizierte Kassetten verwenden („preferred quality“)
  - Idealbetrieb oberhalb der Streaming-Grenze um Start-/Stopp-Betrieb zu vermeiden; ein zeitweises kurzzeitiges Unterschreiten der Streaming-Grenze kann toleriert werden

Plattenspeichersysteme

- Einsatz moderner Plattenspeichersysteme
- Einsatz schneller Platten
- Möglichst großer Cache
  Dieser spielt zwar bei der Datensicherung nur eine geringe Rolle, ist aber bei normalem Betrieb sehr wichtig). Die Größe sollte so gewählt werden, dass bei einem OLTP-Betrieb die Read-Hit-Raten bei 60 - 80% liegen.
- Einsatz der RAID-Level RAID1/0, RAID5 oder RAID6
- Anforderungen zur Konfigurierung aus Sicht von BS2000/OSD berücksichtigen
- Mit PAV und RAID1/0, RAID5 oder RAID6 können auch „große“ Volumes (mit einer Größe von mehr als 32 Gbyte) verwendet werden
- Einsatz von FBA-Platten des Typs D3435 mit Datenformat NK2

6 Performance-Aspekte bei VM2000-Betrieb

VM2000 ermöglicht den gleichzeitigen Ablauf mehrerer, voneinander abgeschotteter BS2000-Gastsysteme auf einem realen S- oder SX-Server. Die einzelnen Gastsysteme laufen auf virtuellen Maschinen (VMs) und verhalten sich funktional wie im Native-Betrieb. Für SQ-Server wird VM2000 zu einem späteren Zeitpunkt zur Verfügung gestellt.

Die Betriebsmittel CPU, Hauptspeicher und Geräte werden durch VM2000 den virtuellen Maschinen und damit den Gastsystemen zugeordnet. Der VM2000-Hypervisor steuert die Betriebsmittelzuteilung an die VMs. Insbesondere ordnet er ablaufbereite virtuelle CPUs der VMs den freien realen CPUs des Servers zu (Scheduling).

VM2000 unterscheidet zwei Prozessorzustände:

- Hypervisor-Modus (in diesem Zustand läuft der VM2000-Hypervisor ab)
- VM-Modus (in diesem Zustand laufen die Gastsysteme ab)

Zu jedem Prozessorzustand gehört ein VM-Kontext (ein Satz von Registern über die Funktionszustände der CPU sowie VM-spezifische Informationen), der bei Aktivierung des Prozessorzustandes geladen wird.

Gegenüber dem Native-Betrieb entsteht VM2000-Overhead:

- Hypervisor-Overhead (Programmablauf im Hypervisor-Modus)
- indirekter Overhead (reduzierte Server-Leistung durch wechselnde VM-Kontexte)

Bei sorgfältiger Konfiguration liegt der VM2000-Overhead unter 10% der Server-Leistung. Die folgenden Abschnitte geben Hinweise zur optimalen Gestaltung des VM2000-Betriebes.

Ausführliche Informationen zu VM2000 finden Sie im Handbuch „VM2000“ [33].

6.1 Verwaltung der CPU-Leistung mit VM2000

Ablaufbeispiele zu den Themen dieses Abschnitts finden Sie im Abschnitt „CPUs verwalten“ des Handbuchs „VM2000“ [33].

6.1.1 VM2000-Scheduling

Beim Scheduling einer VM unter VM2000 bringt der VM2000-Hypervisor eine ablaufbereite virtuelle CPU einer VM auf einer freien realen CPU zum Ablauf. Für das Scheduling benutzt VM2000 zum Ablaufzeitpunkt einer VM zwei unterschiedliche Verfahren:

- CPU-Zuteilung im Zeitscheibenverfahren (siehe unten)
- Feste CPU-Zuordnung (Dedizierte CPUs, siehe Seite 142)

Dabei wird die CPU-Leistung des Servers abhängig von den gewählten Einstellungen für die VMs optimal auf die ablaufbereiten virtuellen Maschinen verteilt.

CPU-Zuteilung im Zeitscheibenverfahren

Im Normalfall ist die Anzahl zugeschalteter realer CPUs in einem CPU-Pool **kleiner** als die Summe der zugeschalteten virtuellen CPUs aller laufenden VMs, die diesem CPU-Pool zugeordnet sind. VM2000 bringt eine virtuelle CPU auf einer realen CPU aus dem CPU-Pool nach einem Zeitscheiben-Verfahren zum Ablauf.

Bis VM2000 V8.0 betrug die Größe der Zeitscheibe für alle VMs statisch 8 Millisekunden. Seit VM2000 V9.0 wird die Größe der Zeitscheibe für jede virtuelle CPU einer VM von VM2000 dynamisch im Intervall von 0,1 bis 8,0 Millisekunden festgelegt. VMs mit einer „sehr kleinen“ CPU-Quota erhalten dann auch eine kleinere Zeitscheibe.

Der VM2000-Administrator kann über VM-spezifische Steuergrößen Einfluss auf die Verteilung der CPU-Leistung nehmen, siehe Seite 141.
Daneben trifft VM2000 noch Maßnahmen zur Performance-Verbesserung:
Wechsel einer virtuellen CPU nur bei IDLE, CPU-Affinität.

Die Scheduling-Priorität der einzelnen Gastsysteme errechnet sich aus den vorgegebenen CPU-Quoten und der in jüngster Vergangenheit verbrauchten CPU-Zeit.

VM-spezifische Steuergrößen

Die performance-relevanten Steuergrößen für eine VM im Zeitscheibenverfahren sind:

- Multiprozessorgrad der VMs/Gastsysteme (siehe Seite 151)
- Privileg IO-PRIORITY (siehe Seite 149)
- CPU-Quote der VM-Gruppe, CPU-Quoten bzw. Mitglieds-CPU-Quoten der VMs (siehe Seite 152)
- Leistungsbegrenzung der VM oder VM-Gruppe (MAX-CPU-UTILIZATION, siehe Seite 142)

Ob ein Gastsystem die ihm zugewiesene CPU-Quote aufnehmen kann, hängt sehr stark vom Nutzungsgrad der VM2000-Zeitscheibe ab, und zwar vom eigenen und von dem der anderen Gastsysteme. Dieser Nutzungsgrad ist bei CPU-intensiven Lasten hoch, bei Ein-/Ausgabe-intensiven Lasten niedrig.

Nutzt ein Gastsystem die ihm zustehende VM2000-Zeitscheibe nicht voll aus, so wirkt sich dies auf das Ein-/Ausgabe-Zeitverhalten der anderen Gastsysteme günstig aus.
Bei einer Multiprozessor-VM versucht VM2000 den nicht genutzten Anteil der VM2000-Zeitscheibe einer virtuellen CPU vorrangig auf die anderen virtuellen CPUs der VM zu verteilen.

Wird dagegen von einem Gastsystem die Zeitscheibe voll ausgenützt, so kann es vor allem für Gastsysteme, deren Last fast nur aus Ein/Ausgabe-intensiven Tasks besteht, zu einer deutlichen Verlängerung der Ein/Ausgabezeiten kommen. Mögliche Maßnahmen sind dann:

- Beschränkung des CPU-intensiven Gastsystems durch MAX-CPU-UTILIZATION (siehe Seite 142) und/oder
- Vergabe des Privilegs IO-PRIORITY (siehe Seite 149)

/SHOW-VM-STATUS INF=*SCHEDULE informiert über den mittleren Wert der genutzten Zeitscheibe eines Gastsystems. Dabei wird die Wartezeit bis zur Aktivierung der virtuellen CPU als Maß für die „Dehnung der VM“ ausgegeben.

CPU-Anteil einer VM

VM2000 gibt in den Informationskommandos verschiedene CPU-Quoten für eine VM oder VM-Gruppe aus, mit denen der VM2000-Administrator die geplante und aktuelle Verteilung der CPU-Leistung beobachten kann:

- CPU-Q (CPU-Quote, /SHOW-VM-ATTRIBUTES/-RESOURCES)
  ist die bei /CREATE-VM oder /MODIFY-VM-ATTRIBUTES eingestellte (MEMBER-)CPU-QUOTA der VM

- EFF-Q (effektive CPU-Quote, `/SHOW-VM-ATTRIBUTES/-RESOURCES`)
  ist die normierte CPU-Quote der VM unter Berücksichtigung der Randbedingungen Multiprozessorgrad und Leistungsbegrenzung der VM
  (Summe der normierten CPU-Quoten aller **eingerichteten** VMs = 100%).
  EFF-Q zeigt den langfristig zu erwartenden CPU-Anteil der VM oder VM-Gruppe bei CPU-intensiver Last in allen Gastsystemen und wenn alle realen und virtuellen CPUs zugeschaltet sind.
- CUR-Q (aktuelle CPU-Quote, `/SHOW-VM-STATUS`)
  ist die normierte CPU-Quote der VM unter Berücksichtigung der Randbedingungen Multiprozessorgrad und Leistungsbegrenzung der VM
  (Summe der normierten CPU-Quoten aller **laufenden** VMs = 100%).
  CUR-Q zeigt den aktuell zu erwartenden CPU-Anteil der VM oder VM-Gruppe bei CPU-intensiver Last in allen Gastsystemen und in Bezug auf die aktuell zugeschalteten realen und virtuellen CPUs.

Leistungsbegrenzung einer VM

Wenn eine VM oder eine VM-Gruppe nie mehr als einen bestimmten Prozentsatz der CPU-Leistung des Servers erhalten soll (auch nicht bei freien CPUs), dann kann dies durch den Parameter `MAX-CPU-UTILIZATION` erreicht werden. Eine begrenzte CPU-Leistung kann z.B. im Rahmen von Service-Levels nötig werden. Der Parameter ermöglicht die Begrenzung überhöhter CPU-Leistungsaufnahme durch ein Gastsystem mit CPU-intensiver Last.

CPU-Affinität

Im Zeitscheibenverfahren strebt VM2000 beim Scheduling an, dass eine virtuelle CPU beim nächsten Scheduling-Vorgang auf der **gleichen** realen CPU zum Ablauf kommt. CPU-Caches und Initialisierungsdaten der VM bleiben erhalten und reduzieren den indirekten Overhead. Vorrangiges Ziel bleibt aber die Optimierung der Antwortzeit.

Feste CPU-Zuordnung (Dedizierte CPUs)

Die Anzahl zugeschalteter realer CPUs in einem CPU-Pool ist **größer oder gleich** der Summe der zugeschalteten virtuellen CPUs aller laufenden VMs, die diesem CPU-Pool zugeordnet sind. VM2000 ordnet jeder virtuellen CPU einer VM in diesem CPU-Pool genau eine reale CPU fest zu.

Der VM2000-Administrator kann in diesem Fall mit dem VM-Attribut `VM-ACTIVE-IDLE` noch bestimmen, ob eine VM auch dann die Kontrolle über eine reale CPU behält, wenn die darauf ablaufende virtuelle CPU der VM untätig ist (unterbrechbarer Wartezustand), siehe Seite 145.

6.1.2 VM-Gruppen

Mehrere VMs können in **VM-Gruppen** zusammengefasst werden.
Die CPU-Nutzung wird dann von VM2000 zweistufig gesteuert. Mit diesem Konzept können logisch zusammengehörende Gastsysteme in Bezug auf die CPU-Nutzung als Einheit betrachtet werden. Z.B. können für einen Kunden mehrere VMs bereitgestellt und mit einem Service-Level versehen werden.

Über folgende Parameter der VM-Gruppen kann der VM2000-Administrator Einfluss auf die Verteilung der CPU-Leistung nehmen:

- die Priorisierung einer VM-Gruppe gegenüber anderen VM-Gruppen oder (Einzel-)VMs erfolgt in der gleichen Weise wie bei (Einzel-)VMs, d.h. über die Parameter `CPU-QUOTA` und `MAX-CPU-UTILIZATION` der VM-Gruppe
- die `MEMBER-CPU-QUOTA` steuert die Priorisierung der VMs, die die VM-Gruppe bilden, untereinander. Für die Scheduling-Priorität wird die `MEMBER-CPU-QUOTA` mit der `CPU-QUOTA` der VM-Gruppe relativiert
- neben der CPU-Leistungsaufnahme VM-Gruppe kann auch die CPU-Leistungsaufnahme jeder VM einer VM-Gruppe durch `MAX-CPU-UTILIZATION` begrenzt werden
- bei VM-Gruppen versucht VM2000 den nicht genutzten Anteil der CPU-Leistung (reale CPU) einer VM vorrangig auf die anderen Mitglieder der VM-Gruppe zu verteilen

VM-Gruppen erzeugen keinen zusätzlichen VM2000-Overhead.

6.1.3 CPU-Pools

Die realen CPUs eines Servers können unter VM2000 in unterschiedliche, disjunkte **CPU-Pools** aufgeteilt werden. Mit diesem Konzept kann eine bessere Hardware-Effizienz und CPU-Affinität bei Servern mit vielen CPUs erreicht werden. Eine VM wird genau einem CPU-Pool zugeordnet.

VM2000 versucht die CPU-Leistung der realen CPUs eines CPU-Pools proportional zu den CPU-Quoten auf die einzelnen Gastsysteme, die einem CPU-Pool zugeordnet sind, aufzuteilen. Eine obere Schranke ergibt sich aus der maximalen CPU-Leistungsaufnahme einer VM.

Folgende Eigenschaften von CPU-Pools haben Einfluss auf die Performance des Servers:

- CPU-Pools reduzieren den VM2000-Overhead, insbesondere bei mehr als 6 CPUs
- CPU-Pools erlauben eine gezielte, aber strikt begrenzte Leistung (Service-Level) für eine Menge von VMs („begrenzte VM-Gruppe“) bei zusätzlich reduziertem VM2000-Overhead

Kriterien für die Gestaltung von CPU-Pools sind:

- Die Größe der CPU-Pools (die Anzahl der einem CPU-Pool zugeordneten realen CPUs) sollte geplant werden, so dass die zur Verfügung gestellte CPU-Leistung der Summe der geplanten Leistungsanteile für die dem CPU-Pool zugewiesenen VMs entspricht.
- Die Auslastung der realen CPUs des Servers sollte möglichst gleich sein. Dementsprechend sollten die CPU-Pools möglichst gleich ausgelastet sein.
- Bei CPU-Pools mit nur einer realen CPU ist zu erwarten, dass die Dehnung der Hardware-Bedienzeit höher ist als bei CPU-Pools mit mehreren realen CPUs.

Wenn sich der Leistungsbedarf der Gastsysteme im Laufe der Session ändert, dann können dem CPU-Pool dynamisch mit `/SWITCH-VM-CPU` neue CPUs hinzugefügt oder CPUs entzogen werden.

Kriterien für die Zuordnung von VMs zu den CPU-Pools sind:

- Bei Gastsystemen mit Anwendungen, deren Antwortzeitverhalten stark von der Dauer der Ein-/Ausgaben abhängt, sollten die konkurrierenden VMs bzw. Gastsysteme im gleichen CPU-Pool sorgfältig ausgewählt werden, damit sich die Dehnung der Hardware-Bedienzeit nicht ungünstig auswirkt.
  Beispielweise sollte vermieden werden, dass einem CPU-Pool viele CPU-intensive Gastsysteme zugeordnet werden.
- Bei Gastsystemen mit besonders hoher Anforderung an die Performance kann der CPU-Pool mit so vielen realen CPUs ausgestattet werden, dass für jede aktive virtuelle CPU eine reale CPU zur Verfügung steht. VM2000 nimmt dann eine feste Zuordnung für das Scheduling vor.
- Mit dem Parameter `VM-ACTIVE-IDLE=*AT-DEDICATED-CPUS` behält eine VM auch dann die Kontrolle über die reale CPU, wenn die darauf ablaufende virtuelle CPU der VM untätig ist (unterbrechbarer Wartezustand). Im dedizierten Scheduling-Modus werden damit die Kontextwechsel beim Gastsystem-Idle vermieden. Auf S-Servern wird damit eine Performance wie im Native-Betrieb erreicht.

6.2 Hauptspeicher

Jedes Gastsystem besitzt exklusiv einen Anteil am Hauptspeicher des Servers (Domäne). Der Zugriff zur Domäne erfolgt so performant wie im Native-Betrieb. Es ergeben sich also die gleichen Zugriffszeiten.

Die Hauptspeicherverteilung (Domänen) sollte geplant vorgenommen werden. Die benötigte Domänengröße für eine VM wird zunächst geschätzt oder aus der bisherigen Systemumgebung abgeleitet. Nach Messung der Paging-Rate mit SM2 muss eventuell eine Korrektur erfolgen. Die Paging-Rate sollte, entsprechend dem Lastprofil (TP- oder Dialog-orientiert), niedrig sein. Die aktuelle Lage und Größe der Domänen kann mit `/SHOW-VM-RESOURCES INF=*MEMORY` ermittelt werden.

Der Hauptspeicherbedarf für eine VM auf einem SX-Server ist wegen der Code-Expansion und dem (residenten) Speicherbedarf für JIT-Puffer höher als bei S-Servern.
Z.B. werden auf SX150 standardmäßig 40% des Hauptspeichers für JIT-Puffer reserviert.

Die Domänengröße für den Hypervisor wird von VM2000 abhängig vom Umfang der Peripherie berechnet.

Die minimale Hauptspeichergröße (`MIN-MEMORY-SIZE`) für eine VM sollte nur festgelegt werden, wenn die Funktionen der Hauptspeicher-Rekonfiguration (`/EXTEND- /REDUCE-VM-MEMORY`) verwendet werden sollen. Sie ist dann so hoch zu wählen, dass mindestens die residenten Speicheranforderungen im Gastsystem befriedigt werden können.

Der Bedarf an residentem Speicher ist abhängig vom Einsatz des Softwareprodukts DAB und auf SX-Servern vom Bedarf der JIT-Puffer.
Noch ohne Berücksichtigung von DAB muss bei SX-Servern folgende Regel beachtet werden (siehe Seite 38): `MIN-MEMORY-SIZE > 1/2 * MEMORY-SIZE`.
Der aktuelle Verbrauch von residentem Speicher kann aus den Werten der Reportgruppe MEMORY von SM2 ermittelt werden: `Residenter Speicher = TOTAL - Pageable Frames`.

Bei SX-Servern ab SX100-D bzw. SX160 und Gastsystemen ab BS2000/OSD V7.0 braucht der JIT-Speicherbedarf bei der Festlegung der `MIN-MEMORY-SIZE` für eine VM nicht mehr berücksichtigt werden.

6.3 Peripherie

Kanäle

Auf S-Servern stehen die Kanäle allen VMs zur Verfügung. Deren Sharing erfolgt über die Firmware. Die Auslastung der Kanäle kann VM-übergreifend mit SM2 beobachtet werden.

Bei SX-Servern zeigt die Firmware nur virtuelle Kanäle für interne Geräte und Geräte am FibreChannel. Eine Beobachtung mit SM2 liefert nur dann aussagekräftige Ergebnisse, wenn bei der Gerätedefinition in PRIMEPOWER ServerView eine sinnvolle Zuordnung gemacht wurde, z.B. pro „Kanal“ eine RAID-Gruppe.

Geräte

Die vorhandenen Geräte werden beim Startup des Monitorsystems und der Gastsysteme dynamisch ermittelt. Damit kennen und verwalten VM2000, das Monitorsystem und alle Gastsysteme die gleichen Geräte.

Periphere Geräte müssen den einzelnen Gastsystemen vor der dortigen Nutzung zugeordnet werden. Dies erfolgt:

- **explizit** durch den VM2000-Administrator mit `/ADD-VM-DEVICES` bzw. `/SWITCH-VM-DEVICES` oder
- **implizit** durch ein Gastsystem mit dem Privileg `ASSIGN-BY-GUEST=*YES(...)` mit `/ATTACH-DEVICE`.
  Der VM2000-Administrator muss dazu für die betreffenden VMs und Geräte diese Art der Zuordnung erlauben.

  Bei der impliziten Zuordnung von Platten wird standardmäßig die Benutzungsart „Shared“ eingetragen.

Periphere Geräte können exklusiv einem einzelnen Gastsystem zugeordnet werden oder als „Shared“-Geräte mehreren Gastsystemen zur Verfügung stehen:

- **Exklusive Zuweisung** = das Gerät ist einem Gastsystem fest zugeordnet

  Die Ein-/Ausgaben werden direkt (ohne Zwischenschaltung des Hypervisors) eingeleitet, also wie im Native-Betrieb.

  Für Gastsysteme im Wartezustand überprüft der Hypervisor das Eintreffen von Ein-/Ausgabe-Termination-Interrupts und initialisiert das entsprechende Gastsystem gemäß seiner Scheduling-Priorität. Dieser Hypervisor-Aufwand ist minimal.

- **„Shared“ Zuweisung** = das Gerät steht mehreren Gastsystemen zur Verfügung

  Die Art der Abwicklung der Ein-/Ausgabe ist von folgender Bedingung abhängig:

  a) Ist das Gerät nur einem Gastsystem zugeordnet, so werden die Ein-/Ausgaben direkt, d.h. ohne Zwischenschaltung des Hypervisors, durchgeführt („Direct-I/O“). In den Informationskommandos von VM2000 wird das Gerät durch die Anzeige SH(D) gekennzeichnet, im DEVICE DISK-Report von SM2 durch die Anzeige D.

  b) Ist das Gerät mehreren Gastsystemen zugeordnet, so unterbricht der Hypervisor auf S-Servern alle Ein-/Ausgaben der Gastsysteme und serialisiert sie („Indirect-I/O“).
  In den Informationskommandos von VM2000 wird das Gerät durch die Anzeige SH(I) gekennzeichnet, im DEVICE DISK-Report von SM2 durch die Anzeige I.

  Der CPU-Bedarf des Hypervisors steigt für gemeinsam benutzte Geräte linear mit der Ein-/Ausgaberate. Der VM2000-Overhead beträgt 1 RPF bei 100 Ein-/Ausgaben pro Sekunde.

  Auf SX-Servern werden Platten-Ein-/Ausgaben als logische Aufträge über die RSC-Schnittstelle ausgeführt. Der Hypervisor-Overhead für die Serialisierung entfällt.

Bedienzeiten von Geräten (Messprogramm SERVICETIME von SM2) können von genau einer VM ermittelt werden.

Privileg IO-PRIORITY

Anwendungen führen meist synchrone Ein-/Ausgaben aus. Nach deren Start wartet die Task auf das Ende der Ein-/Ausgabe. Wenn kein weiterer Task ablaufbereit ist, erfolgt der Übergang in den IDLE-Zustand und die reale CPU wird durch den Hypervisor neu verteilt. Nach Ende der Ein-/Ausgabe muss das Gastsystem auf die erneute Zuordnung einer realen CPU warten, bevor es das Ende der Ein-/Ausgabe bearbeiten kann. Die Verzögerung zwischen dem tatsächlichen Ende der Ein-/Ausgabe und ihrer Bearbeitung im Gastsystem wird als **Dehnung der Hardware-Bedienzeit** oder als **IO-Dehnung** bezeichnet.

CPU-intensive Gastsysteme können dadurch den Betrieb Ein-/Ausgabe-intensiver Gastsysteme stören. Hinweise darauf gibt `/SHOW-VM-STATUS INF=*SCHEDULE`, Ausgabespalten `%RUNOUT` und `%WAIT`.

Die IO-Dehnung ist um so geringer, je rascher dem Gastsystem wieder die CPU zugeteilt wird. Dazu kann auf S-Servern einer VM das Privileg `IO-PRIORITY=*YES` zugeordnet werden. Befindet sich eine virtuelle CPU einer solchen VM im Wartezustand, so wird diese beim Eintreffen eines Ein-/Ausgabe-Termination-Interrupts vom Hypervisor sofort auf einer realen CPU zum Ablauf gebracht, um das Ergebnis der Ein-/Ausgabe zu bearbeiten. Die Laufzeiten von Ein-/Ausgabe-kritischen Jobs verbessern sich deutlich.

Dem positiven Effekt, dass gleich gute Hardware-Bedienzeiten wie im Native-Betrieb erreicht werden, steht eine erhöhte Scheduling-Rate gegenüber. Pro Gastsystem mit Privileg `IO-PRIORITY` ist mit einem zusätzlichen CPU-Bedarf von bis zu 5 Prozentpunkten für den VM2000-Overhead zu rechnen.

Es wird daher empfohlen, die Gastsysteme zunächst ohne Privileg einzurichten (also mit `IO-PRIORITY=*NO`) und erst im Bedarfsfall das Privileg `IO-PRIORITY=*YES` zu vergeben.

Das Privileg `IO-PRIORITY=*YES` bringt bei dedizierten CPUs keine Vorteile.

Unterstützung des Dienstprogramms IORM (I/O Ressource Manager)

Das Dienstprogramm IORM (siehe Handbuch „Dienstprogramme“ [7]) wird durch VM2000 unterstützt. Im VM2000-Betrieb sollte IORM auf dem Monitorsystem und allen Gastsystemen im Einsatz sein.

Folgende IORM-Funktionen werden im Zusammenspiel mit VM2000 ausgeführt:

- Dynamische I/O-Lastverteilung für Platten am FC-Kanal mit DPAV im VM2000-Betrieb (nur S-Server)

  Dynamisches PAV (DPAV) weist autonom denjenigen Volumes Alias-Geräte zu, die am meisten davon profitieren. Im VM2000-Betrieb wird das eigentliche Umschalten von Alias-Geräten von DPAV im Monitorsystem koordiniert und durchgeführt.

  Unter VM2000 wird DPAV für Gastsysteme ab BS2000/OSD V5.0C angeboten.

- Optimierte Geräteauswahl im ETERNUS CS (CentricStor)-Betrieb unter VM2000 mit DDAL (Dynamic Device Allocation)

  Alternativ zur Nutzung der Geräte gemäß ihrer Generierung (wie in den Vorversionen) kann das Betriebssystem eine gleichmäßige Auslastung aller verfügbaren ICPs (Integrated Channel Processor) sicherstellen.

  Unter VM2000 weitet die IORM-Funktion DDAL die optimierte (lokale) Geräteauswahl auf alle BS2000/OSD-Gastsysteme ab V7.0 eines Servers aus. Obwohl die optimierte (lokale) Geräteauswahl erst ab BS2000/OSD V7.0 zur Verfügung steht, ist es sinnvoll, DDAL auch in Gastsystemen BS2000/OSD V6.0 zu aktivieren. In den Gastsystemen BS2000/OSD V6.0 können dann die Belegungszähler ermittelt und einem Gastsystem BS2000/OSD V7.0 zu Verfügung gestellt werden.
  DDAL ist für Gastsysteme BS2000/OSD V5.0 nicht verfügbar.

- Begrenzung der I/O-Leistungsaufnahme einzelner VM2000-Gastsysteme mit IOLVM (I/O Limit for Virtual Machines)

  Im VM2000-Betrieb können weniger wichtige, jedoch Ein-/Ausgabe-intensive Gastsysteme andere, wichtigere Gastsysteme im Ein-/Ausgabe-Betrieb behindern.

  Die Funktion IOLVM des Dienstprogramms IORM kann solche Konfliktsituationen erkennen und bremst gezielt den Ein-/Ausgabebetrieb des eigenen Gastsystems, wenn gemeinsam benutzte I/O-Ressourcen (Kanal, Port, Pfad, Platte) das Gastsystem-spezifische I/O-Limit überschreiten.

  Seit VM2000 V9.0 wird das I/O-Limit für IOLVM als maximale I/O-Leistungsaufnahme der VM im Operanden `MAX-IO-UTILIZATION` in den VM2000-Kommandos `/CREATE-VM` bzw. `/MODIFY-VM-ATTRIBUTES` festgelegt. Diese Einstellung wirkt für alle Gastsysteme BS2000/OSD ab V5.0.

6.4 Gastsystem-Planung

6.4.1 Anzahl und Multiprozessorgrad der VMs

Anzahl und Multiprozessorgrad der VMs und damit der Gastsysteme haben Einfluss auf die Performance des Servers. Aufgrund von Messungen und Erfahrungen werden folgende Obergrenzen für die Anzahl der VMs empfohlen:

Serverleistung in RPF (Relativer Performance Faktor)	Anzahl VMs / Gastsysteme (Gastsysteme mit Produktionslast)
bis 60	3
60 - 120	4
120 - 180	5
180 - 240	6
240 - 300	7
> 300	8

Gesamtanzahl und Multiprozessorgrad der VMs beeinflussen den VM2000-Overhead:

- Gesamtzahl der VMs bzw. Gesamtzahl der virtuellen CPUs
  - Je mehr unterschiedliche virtuelle CPUs auf einer realen CPU zum Ablauf kommen, desto weniger optimal wirken die CPU-Caches.

    VM2000 reduziert durch CPU-Affinität (siehe Seite 142) die Anzahl der CPU-Wechsel virtueller CPUs.
    Mit CPU-Pools kann die Menge der ablaufenden virtuellen CPUs pro realer CPU eingeschränkt werden.
  - Der Hypervisor-Overhead zur Verwaltung der CPU-Queues hängt direkt von der Anzahl virtueller CPUs ab.

    Das Verhältnis der Anzahl der aktiven virtuellen CPUs (der Gastsysteme mit Produktionslast) zur Anzahl der realen CPUs sollte in allen CPU-Pools kleiner oder gleich 3 sein.
    Die Anzahl der Gastsysteme sollte dementsprechend klein sein.
- Multiprozessorgrad einer VM (= maximale Leistungsaufnahme der VM)

  Die Auslastung der virtuellen CPUs einer VM beeinflusst den Nutzungsgrad der VM2000-Zeitscheibe und damit die Häufigkeit der Scheduling-Vorgänge. Hoher Nutzungsgrad der VM2000-Zeitscheibe und niedrige Häufigkeit der Scheduling-Vorgänge sind performance-günstig.

Der Multiprozessorgrad einer VM sollte sich am Spitzenbedarf des Gastsystems orientieren. Er sollte möglichst niedrig gewählt werden. Die Auslastung pro virtueller CPU (Messwert `VM-ACTIVE: TIME/%` pro virtueller CPU) sollte möglichst nicht unter 60% liegt. Gleichzeitig sollten Werte über 80% vermieden werden. Bei geringer Last sollten virtuelle CPUs im Gastsystem weggeschaltet werden.

6.4.2 Einstellung der CPU-Quoten

Die Einstellung der CPU-Quoten für die VMs sollte in mehreren Schritten erfolgen:

1. Grobeinstellung der CPU-Quoten

In erster Näherung wird empfohlen, die CPU-Quoten proportional zum erwarteten CPU-Verbrauch der einzelnen Gastsysteme festzusetzen. Dabei sollten auch die Reserven proportional verteilt werden.

Beispiel

Auf einem Bi-Prozessor sind zwei Gastsysteme (VM1, VM2) geplant, welche schätzungsweise 50% bzw. 30% der Rechnerleistung benötigen. Die verbleibenden 20% werden proportional verteilt, d. h. 12,5% für VM1 und 7,5% für VM2.

Es ergeben sich die folgenden CPU-Quoten:

VM1 50 + 12,5 = 62,5%
VM2 30 + 7,5 = 37,5%

Da das Gastsystem VM2 den Server nur zu ca. 30% auslasten wird, soll es als Mono-Gastsystem betrieben werden. Das Gastsystem VM1 benötigt auf jeden Fall beide CPUs.

2. Leistungsbegrenzung

Die Begrenzung der CPU-Leistung für eine VM (siehe Seite 142) ist so zu wählen, dass deren normale Leistungsaufnahme bei etwa 70% der Leistungsbegrenzung liegt.

3. Messung

Mit `/SHOW-VM-STATUS INF=*TIMER` und SM2 (siehe Seite 158) werden die VM und das Gastsystem beobachtet. Anhand der Messwerte ist zu prüfen, ob der tatsächliche CPU-Zeitverbrauch und das Performance-Verhalten den Erwartungen entsprechen.

Wenn die Gastsysteme annähernd die erwartete Leistung aufnehmen, kann die Einstellung so belassen werden.

4. Leistungsbedarf prüfen

Wenn die Gastsysteme **nicht** die erwartete Leistung aufnehmen, dann ist zu prüfen, wie hoch der CPU-Bedarf der einzelnen Gastsysteme tatsächlich ist. Dazu wird nacheinander jedem Gastsystem eine sehr hohe CPU-Quote zugewiesen, sodass der Wert `CUR-Q` sehr viel höher als der Prozentwert von `VM-ACTIVE` ist.

Man kann dann davon ausgehen, dass der gemessene Prozentwert `VM-ACTIVE` dem tatsächlichen CPU-Bedarf des Gastsystems entspricht. Die CPU-Quoten können jetzt anhand dieser Werte neu berechnet werden.

Im Hinblick auf die Belastung des Servers durch sämtliche Gastsysteme zusammen, empfiehlt es sich, CPU-Auslastungen (= `100 - HYPERVISOR IDLE`) > 90% zu vermeiden.

5. Feineinstellung der CPU-Quoten

Auch nach korrekter Grobeinstellung (d. h. CPU-Quoten entsprechen dem Leistungsbedarf der Gastsysteme), kann die Leistungsaufnahme einzelner Gastsysteme stark vom erwarteten Wert abweichen. Ein-/Ausgabe-intensive Gastsysteme nehmen i.d.R. unter Soll, CPU-intensive Gastsysteme über Soll an Leistung auf.

Ferner kommt es vor, dass die Antwortzeiten wichtiger Anwendungen nicht den Anforderungen entsprechen. In solchen Fällen muss nachgebessert werden, d. h. einzelne CPU-Quoten werden höher („Überplanung“) bzw. niedriger eingestellt, als die Grobeinstellungs-Empfehlung vorgibt.

Die Korrekturen der CPU-Quoten können durchaus eine Größenordnung von Faktor 2 annehmen. Ob und wie stark nachgebessert wird, hängt von den Performance-Anforderungen an die Gastsysteme ab. In diesem Schritt ist eine enge Zusammenarbeit mit den Gastsystem-Verwaltern unerlässlich.

6. VM-Gruppen bilden

Abschließend können VMs zu VM-Gruppen zusammengefasst werden.

Bei Nutzung von VM-Gruppen ist eine Feineinstellung der `MEMBER-CPU-QUOTA` für die Gruppenmitglieder ebenfalls zu empfehlen.

Eine Überplanung der `CPU-QUOTA` der VM-Gruppe wird nicht empfohlen. Falls eine Überplanung notwendig sein sollte, so sollten anstelle von VM-Gruppen einzelne VMs geplant werden.

6.5 Systembetreuung im Gastsystem

VMs bzw. Gastsysteme mit Batch-orientierter, CPU-intensiver Last werden vom VM2000-Scheduling bevorzugt. Dialog-orientierte Gastsysteme mit häufigen Idle-Zeiten werden durch die IO-Dehnung in ihren Antwortzeiten behindert. Nötigenfalls muss eine Feineinstellung der CPU-Quoten erfolgen, siehe Seite 153.

Die Task-Prioritäten in einem Dialog-orientierten Gastsystem wirken weniger stark.
Die Prioritäten müssen ggf. neu eingestellt werden, siehe folgenden Abschnitt.

Ein Gastsystem, das seine Zeitscheibe (normalerweise 8 Millisekunden, siehe Seite 140) nur in geringem Umfang nutzt, wird einerseits durch die IO-Dehnung, andererseits durch schlechtere Cache-Hitraten gegenüber dem Native-Betrieb behindert. Insbesondere auf S-Servern kann der Ablauf in einem CPU-Pool mit dedizierten CPUs und dem Parameter `VM-ACTIVE-IDLE` helfen, siehe Seite 142.

Bei Einsatz von PCS kann die Dehnung einer Kategorie in beide Richtungen beeinflusst werden, siehe Abschnitt „PCS unter VM2000“ auf Seite 156.

6.5.1 Einstellung der Prioritäten

Teilt man eine IT-Last auf mehrere Gastsysteme auf, so verändert sich die Konkurrenzsituation der einzelnen Lastkomponenten. Daher müssen manchmal Prioritäten neu eingestellt werden. Dies soll an folgendem Beispiel erläutert werden.

Auf einem Server im Native-Betrieb laufen folgende Lastkomponenten:

- eine UDS/UTM-Anwendung
- mehrere Batch-Datenbankanwendungen
- einige Dialog-Tasks mit Programmentwicklungstätigkeit ohne Datenbankzugriff

Prioritäten und CPU-Verbrauch waren bisher wie folgt:

	UDS-Tasks	**UTM-Tasks**	**Batch**	**Dialog1**	**Dialog2**
Task-Anzahl	1	8	2 - 6	3	10
Priorität	150	150	255	180	210
Auslastung (%)	20	30	10	5	10

Jetzt soll die IT-Last folgendermaßen auf zwei Gastsysteme aufgeteilt werden: Die Entwicklertätigkeiten sollen auf ein eigenes Gastsystem ausgelagert werden. Alle anderen Komponenten sollen wegen der gemeinsam genutzten Datenbanken auf einem anderen System laufen.

VM	Bezeichnung	CPU-Quote	Last
VM1	TP-System	80	UDS/UTM + Batch
VM2	Dialog-System	20	Dialog1 + Dialog2

Infolge der wegfallenden Dialog-Last verbessert sich die Situation für die Batch-Tasks, da diese nun immer dann laufen können, wenn die TP-Last auf Ein-/Ausgaben wartet. Der Durchsatz CPU-intensiver Batch-Tasks verbessert sich, da diese die reale CPU an das Gastsystem binden.

Reine Dialogsysteme haben gewöhnlich einen hohen Idle-Anteil. Wegen der niedrigen CPU-Quote muss das Dialog-System nach jedem IDLE-Zustand relativ lange warten. Dadurch können sich die Antwortzeiten der Dialoge verschlechtern.

Auch die Bevorzugung der höher prioren Dialoge gegenüber den niedriger prioren nimmt ab. Um nach der Lasttrennung dieselben Ergebnisse zu erhalten, sind folgende Maßnahmen durchzuführen:

- Bei gravierender Verschlechterung der Dialog-Antwortzeiten muss die CPU-Quote des Dialogsystems erhöht werden. Dabei sind immer die TP-Antwortzeiten und der Batch-Durchsatz zu beobachten.
- Der Prioritätsabstand zwischen Dialog1 und Dialog2 muss vergrößert werden.
- Die Prioritäten der UDS- und UTM-Tasks müssen noch etwas verbessert werden, um den ursprünglichen Abstand zu den jetzt besser gestellten Batch-Tasks wieder herzustellen.

6.5.2 PCS unter VM2000

Läuft PCS (Performance Control Subsystem) unter VM2000, so wird intern die CPU-Quota des entsprechenden Gastsystems berücksichtigt, d.h. innerhalb eines Gastsystems sollte die Summe des S-Q MAX-Wertes für antwortzeitkritische Katagorien bei 100 liegen (≙ 100% der Gastsystem-Kapazität).
Gegenüber dem Native-Betrieb ist i.d.R. eine Korrektur der Parametrisierung der SERVICE-Bereiche (Bereich zwischen SERVICE-QUOTA MIN und MAX, gesteuert über die Dehnungsparameter REQUEST-DELAY MIN und MAX) erforderlich.

Die Dehnung (REQUEST-DELAY, siehe auch Abschnitt „Einführung in das PCS-Konzept“ auf Seite 243) ist folgendermaßen definiert:

$$\text{Dehnung} = \frac{\text{Laufzeit im Multiprogramming-Betrieb}}{\text{Alleinlaufzeit}}$$

Unter VM2000 können sich nun beide Laufzeiten verlängern. Die Alleinlaufzeit kann zum Beispiel durch die Verlängerung der Ein-/Ausgabezeiten durch andere Gastsysteme oder durch die Verminderung der Hardware-Leistung infolge geringerer Cache-Hitrate zunehmen.

Abhängig vom Lastprofil der einzelnen Kategorien eines Gastsystems und den Lastprofilen der anderen Gastsysteme können sich daher die PCS-Dehnungen von Kategorien gegenüber einem vergleichbaren Native-Betrieb sowohl vergrößern (was grundsätzlich zu erwarten wäre) als auch verkleinern.

Bei der Überprüfung bzw. Korrektur der Parameter SERVICE-QUOTA und REQUEST-DELAY sollte in folgender Reihenfolge vorgegangen werden:

- SERVICE-QUOTA MIN
  Damit wird die Service-Quote eingestellt, die eine Kategorie im Normalbetrieb benötigt, also ohne Berücksichtigung von Lastspitzen.
- SERVICE-QUOTA MAX
  Maximaler Prozentanteil am Leistungsvermögen des Gastsystems, der einer Kategorie für den Lastspitzenfall zugestanden wird.
- REQUEST-DELAY MIN
  Der Systemverwalter sollte durch wiederholte Messungen herausfinden, ab welchem Wert REQUEST-DELAY ACTUAL ein Engpass bzw. unbefriedigendes Kategorieverhalten vorliegt, d. h. eine Erhöhung der Service-Rate erwünscht ist. Auf diesen Wert wird dann REQUEST-DELAY MIN eingestellt.
- REQUEST-DELAY MAX
  Hiermit wird festgelegt, wie heftig einer Lastspitze entgegen gesteuert werden soll. Je näher der Wert bei REQUEST-DELAY MIN liegt, je kleiner er also ist, desto stärker ist die Reaktion auf Lastspitzen.

6.5.3 Gastsystem-Bedienung

Es wird aus Performance-Gründen empfohlen, die Gastsysteme über Bedienstationen zu bedienen.

Gastsysteme können auch über virtuelle Konsolen (über $VMCONS) bedient werden. In diesem Fall sollte nur die Basisbedienung (Startup) über virtuelle Konsole abgewickelt werden. Die eigentliche Bedienung sollte über logische Konsolen mittels OMNIS durchgeführt werden.

OMNIS schließt sich direkt an $CONSOLE des entsprechenden Gastsystems an und umgeht somit $VMCONS. Die Synchronisation der Aufträge an $VMCONS erfolgt über eine Börse. Diese Börse kann bei vielen Gastsystemen bzw. vielen Konsol-Ein-/Ausgaben zum Engpass werden.

6.6 Messwerkzeuge für VM2000

Es gibt zwei Messwerkzeuge für den VM2000-Betrieb:

- `/SHOW-VM-STATUS` führt im Monitorsystem Messungen auf VM2000-Ebene für VMs, VM-Gruppen, CPU-Pools und reale CPUs durch. Dabei werden zum Teil auch VM2000-internen Performance-Kenngrößen ausgegeben. Gemessen werden können die Hypervisor-Aktivitäten, Plan- und Ist-Werte der CPU-Auslastung und Daten des VM2000-Scheduling.
  Mit dem Kommando können sowohl periodischen Messwerte als auch Messwerte der unmittelbaren Vergangenheit ausgegeben werden.
- das Mess-System openSM2 mit Online-Reports (INSPECTOR) und Langzeitauswertungen (ANALYZER).

Für die Beobachtung der Leistungsaufnahme der Gastsysteme und des Hypervisors mit openSM2 sind folgende ANALYZER-Reportgruppen zu empfehlen.

- In den Gastsystemen

  CPU: CPU-Utilization
  CPU-Auslastung in den Funktionszuständen TU, TPR, SIH. Diese Werte sind die vom jeweiligen Gastsystem ermittelten Auslastungswerte (bezogen auf die Anzahl der dem Gastsystem zur Verfügung stehenden virtuellen CPUs!).

- Im Monitorsystem

  VM2000: VM2000-Utilization/VM2000-Hypervisor
  CPU-Verbrauch, aktuelle CPU-Quota und aktuelle maximale Leistungsaufnahme pro VM. CPU-Verbrauch des Hypervisors und Hypervisor-Idle.

  VM2000: CPU-Pool
  CPU-Auslastung und Dimensionierung der CPU-Pools.

  VM2000: VM-Gruppen
  CPU-Verbrauch, aktuelle CPU-Quota und aktuelle maximale Leistungsaufnahme pro VM-Gruppe.

Einige SM2-Messwerte müssen bei VM2000-Betrieb neu interpretiert werden. Eine detaillierte Beschreibung befindet sich im Abschnitt „SM2-Einsatz bei VM2000-Betrieb“ des Handbuchs „openSM2“ [19].

7 Leistungsverhalten der Software

Dieses Kapitel behandelt die Performance-Kriterien beim Einrichten der Systemumgebung. Unter dem Begriff „Systemumgebung“ ist das gesamte Umfeld der Anwenderprogramme zu verstehen. Die Systemumgebung setzt sich zusammen aus dem Systemkern und den Subsystemen.

Systemkern

Der Systemkern von BS2000/OSD besteht aus Basissteuermechanismen und unterstützenden System-Tasks zur optimalen Nutzung der Betriebsmittel und zur Verständigung zwischen Anwender und Maschine sowie aus Systemroutinen zur Erleichterung der Programmierung. Die Aufgaben des Systemkerns, dem die höchste Priorität zugeordnet ist, lassen sich wie folgt zusammenfassen:

- Job-Management

  Stellt die Verbindung nach außen dar:
  – Logon und Logoff-Behandlung für die Benutzer der Terminals
  – Verständigung mit dem Operator
  – Verarbeitung des Auftrags-Eingabestroms

- Task-Management

  Steuert und überwacht mit Hilfe der Basissteuermechanismen die Ausführung der User- und System-Tasks:
  – Unterbrechungsanalyse
  – Erzeugen und Beenden von Tasks
  – Verwaltung der Betriebsmittel Hauptspeicher und CPU
  – Steuerung der Tasks über Warteschlangen

- Data-Management

  Übernimmt die Maßnahmen, die zur Behandlung von Datenbeständen erforderlich sind:
  – Abwicklung der Ein-/Ausgabe zwischen Hauptspeicher und Ein-/Ausgabe-Einheiten
  – Verwaltung der Datenträger
  – Logische Zugriffsmethoden (SAM, ISAM, PAM, FASTPAM, DIV, BTAM)
  – Unterstützung der HIPERFILEs zusammen mit DAB
  (siehe Abschnitt „Arbeiten mit HIPERFILEs“ auf Seite 195)

Um den Systemkern werden Subsysteme je nach den zu bewältigenden Aufgaben angeordnet (z.B. Editierhilfen, Compiler, DFÜ-Komponenten, Datenbanken).

Subsysteme

Die Subsysteme gliedern sich in zwei Gruppen:

- Privilegierte Subsysteme

  Diese laufen im Funktionszustand TPR ab (z.B. SPOOL, NDM) und sind mit dem Systemkern so eng verbunden, dass sie nicht mit den für den Anwender bestimmten Ladeprogrammen geladen werden können.

- Nichtprivilegierte Subsysteme

  Sie haben gegenüber BS2000/OSD den Status von normalen Anwenderprogrammen und bedienen sich daher auch nur der für den Anwender offenen Schnittstellen (z.B. Compiler, Editoren, Datenbanken, Dienstprogramme).

Einrichten der Systemumgebung

Ausgehend vom Systemkern bezeichnet man alle Tätigkeiten zur Erstellung eines aufgabenbezogenen Betriebssystems als Einrichten der Systemumgebung. Die Systemeinrichtung beinhaltet:

- Einstellen der Größe des Benutzeradressraums für S-Server
  (siehe Abschnitt „Größe des Benutzeradressraums“ auf Seite 161)
- Einrichten der Dateien
  (siehe Abschnitt „Performance-Kriterien beim Einrichten von Dateien“ auf Seite 163)
- Festlegen der HIPERFILEs
  (siehe Abschnitt „Arbeiten mit HIPERFILEs“ auf Seite 195)

Die nachfolgenden Hinweise sollen helfen, diese Arbeiten so auszuführen, dass die Leistungsfähigkeit von BS2000/OSD voll genutzt werden kann.

7.1 Größe des Benutzeradressraums

SX- und SQ-Server

Der Benutzeradressraum für SX- und SQ-Server ist in der Größe von 2 GB generiert und kann nicht verändert werden.

S-Server

Bei S-Servern setzt sich der Gesamtadressraum zusammen aus dem Benutzeradressraum (inklusive des Platzbedarfs der Shared-Produkte, Parameter SHRSIZE) und dem Systemadressraum. Für die Größe des Gesamtadressraums stehen auf S-Servern die Werte 1 GB oder 2 GB zur Verfügung.

Durch die Größe des Benutzeradressraums ergibt sich automatisch die Größe des Systemadressraums als Differenz zum nächsthöheren Wert des Gesamtadressraums.
Die Angabe des Parameters SYSSIZE im Parameterservice ist bei der Systemeinleitung nicht mehr erforderlich.

Für S-Server wird standardmäßig ein Benutzeradressraum von 1.808 MB generiert. Diese Größe kann mit der Prozedur `SYSPRC.BS2000-EXEC.<version>` geändert werden (siehe Handbuch „Systeminstallation“ [31]).

Bei Konfigurationen mit höherem Bedarf an Systemadressraum muss der Benutzeradressraum auf 1.792 MB (SYSSIZE=256 MB), 1.664 MB (SYSSIZE=384 MB) oder 1.536 MB (SYSSIZE=512 MB) reduziert werden.

Die Unterteilung des Gesamtadressraums wurde u.a. zur Minderung des Hauptspeicher-Bedarfs für die Adressraumverwaltung (Segmenttafel) eingeführt. Abhängig von der Größe des Gesamtadressraums (1 oder 2 GB) wird folgender Hauptspeicher pro Task für die Segmenttafeln belegt:

4 KB	bei	1.024 MB	Gesamtadressraum
8 KB	bei	2.048 MB	Gesamtadressraum

Bei einer kleinen Anzahl von Tasks ist die Auswahl des größtmöglichen Adressraums (2 GB) unkritisch. Bei einer großen Anzahl von Tasks muss geprüft werden, ob der Mehrbedarf an Hauptspeicher durch einige Großanwendungen gerechtfertigt ist.

Pro MB belegtem Adressraum und Task werden für die Seitentafel-Verwaltung 3 KB Hauptspeicher benötigt. Belegen z.B. 10 Tasks vollständig den maximal zur Verfügung stehenden Benutzeradressraum von 1.808 MB, so wird allein für die Adressraumverwaltung (Segmenttafel und Seitentafel) folgender Hauptspeicher (residenter Klasse-3-Systemadressraum) benötigt:

10 •	8 KB	=	80 KB	für Segmenttafel
10 •	1.808 MB • 3 KB/MB	=	54.240 KB	für Seitentafel
			54.320 KB	

Bei großen virtuellen Adressräumen ist auf ausreichend dimensionierte Seitenwechselbereiche zu achten. Die benutzerspezifische Größe (`/ADD-USER`, `/MODIFY-USER-ATTRIBUTES`) ist sorgfältig festzulegen. Die Nutzung vieler großer Adressräume setzt einen entsprechend groß dimensionierten Hauptspeicher voraus.

7.2 Performance-Kriterien beim Einrichten von Dateien

BS2000-Benutzer und Systemadministratoren können zumeist nur die Lage der Dateien bzgl. der logischen Volumes beeinflussen. Auf physikalischer Ebene können sich mehrere logische Volumes auf einer gemeinsamen physikalischen Platte befinden. Die daraus resultierenden Auswirkungen auf die Performance und die Performance-Maßnahmen sind im Abschnitt „Konfigurierung in BS2000/OSD“ auf Seite 66 beschrieben.

In den folgenden Abschnitten dieses Kapitels wird für den (aktuellen) Begriff „logisches Volume“ als Synonym weiterhin der (bisherige) Begriff „Platte“ verwendet.

7.2.1 Logische Betriebsarten von Platten

Platten werden in BS2000/OSD logisch über die Volume-Serial-Number (VSN) angesprochen. Der Betrieb eines Volumes ist möglich als

- Public-Volume innerhalb von
  - SF-Pubsets (Single-Feature-Pubsets)
  - SM-Pubsets (System-Managed-Pubsets)
  - Shared-Pubsets bei Mehrrechnerzugriff
- Private-Volume bei Mehrrechnerzugriff als SPD (Shared-Private-Disk)

Gleichgültig, welche logische Betriebsart zum Einsatz kommt, die Zeit für die Abwicklung des einzelnen Zugriffs zu den Daten ist – bei gleichem Plattentyp – etwa gleich lang.

Durch den unterschiedlichen Aufwand bezüglich der Speicherplatzverwaltung bzw. der Koordinierung des Mehrrechnerzugriffs ergeben sich jedoch gravierende Unterschiede hinsichtlich der Anzahl durchzuführender Ein-/Ausgaben bei Aufruf von Funktionen mit Katalogzugriff.

Zusätzlich gibt es zur Erhöhung der Verfügbarkeit die Betriebsarten:

- Dual Recording by Volume (DRV)
  Datenspiegelung, gesteuert durch BS2000/OSD
  (Softwareprodukt DRV, siehe dazu Handbuch „DRV“ [8])
- Plattenspiegelung (Mirroring)
  Datenspiegelung, gesteuert durch die Plattenspeichersysteme Symmetrix oder FibreCAT CX

  Die Datenspiegelung ist ein Teil des RAID-Konzepts.
  RAID (Redundant Arrays of Independent Disks) ist eine Architektur, die die Abbildung mehrerer physikalischer Plattenlaufwerke auf ein logisches Volume definiert, um Datenredundanz zu erzielen, siehe Seite 61).

Public Volumes

Die Speicherplatzverwaltung erfolgt durch das System und bietet die optimale Unterstützung für Aufrufe mit Katalogzugriff:

- Hoher Komfort für den Anwender durch stark vereinfachte Definitionen beim Einrichten, Erweitern und Löschen von Dateien.
- Geringere Anzahl von Verwaltungs-Ein-/Ausgaben gegenüber den Private-Volumes (Verwaltung der F5-Kennsätze im Hauptspeicher, Unterstützung durch das Softwareprodukt SCA, siehe Seite 168).

Die explizite Vorgabe der Lage einer Datei kann für alle Pubsets durch die Systembetreuung erfolgen. Für den Anwender ist dies nur möglich, wenn im pubset-spezifischen Benutzerkatalog das Recht zur physikalischen Allokierung eingetragen ist (`/MODIFY-USER-ATTRIBUTES`, Operand `PHYSICAL-ALLOCATION`). Dies ist wichtig beim Einrichten spezieller Systemdateien (siehe Abschnitt „Einrichten von Systemdateien“ auf Seite 174).

Mit steigender Leistungsfähigkeit der Server nimmt auch die Anzahl der erforderlichen Public-Volumes stark zu. Aus Performance- und Verfügbarkeitsgründen ist deshalb die Aufteilung des Public-Pools in mehrere Pubsets grundsätzlich anzustreben.

Pubsets sind die stategische Plattform für Weiterentwicklungen im Plattenbereich. Private-Volumes bieten nicht die volle funktionale Unterstützung neuer Funktionen, z.B. im HIPERFILE-Konzept.
Ein Umstieg von privaten Volumes auf Pubsets wird daher empfohlen.

SF-Pubsets

Für die Speicherplatzverwaltung gilt das gleiche wie bei Public-Volumes beschrieben. Zusätzlich zur Erhöhung der Verfügbarkeit ergeben sich aus Performance-Sicht folgende Vorteile (besonders wichtig bei Dialogbetrieb):

- Die Splittung des Dateikatalogs TSOSCAT auf die einzelnen Pubsets verbessert die Katalog-Performance bei intensiver Nutzung von Katalogfunktionen.
- Durch die Möglichkeit zur Steuerung der Ein-/Ausgabe-Verteilung über die Benutzerkatalog-Einträge durch die Systembetreuung können Anwendern mit besonders zugriffsintensiven Dateien getrennte Daten-Pubsets zugewiesen werden.

SM-Pubsets

SM-Pubsets bestehen aus mehreren Volume-Sets, die verschiedene, von der Systembetreuung vorgegebene Eigenschaften hinsichtlich Formatierung, Verfügbarkeit und Performance aufweisen können.

Im Vergleich zu SF-Pubsets, die aus genau einem Volume-Set bestehen, bieten SM-Pubsets eine bessere Steuerung der Ein-/Ausgabe-Verteilung durch die Systembetreuung bei gleichzeitig höherem Komfort für den Anwender:

- Durch die Angabe von Direktattributen oder einer Storage-Klasse kann der Anwender beim Einrichten einer Datei ihren Ablageort auf einem SM-Pubset bestimmen.
- Die Systembetreuung ordnet jeder Storage-Klasse eine Volume-Set-Liste zu und definiert pro Volume-Set die gewünschten Performance-Anforderungen.

Ausführliche Informationen zu SMS (System Managed Storage) bzw. SM-Pubsets können dem Handbuch „SMS“ [32] entnommen werden.

Shared-Pubsets

Zwei oder mehrere gleichzeitig schreibberechtigte Server (oder VM2000-Gastsysteme) können auf gemeinsame Pubsets zugreifen (Ausnahme: Home- bzw. Paging-Pubsets). Die Server sind über eine BCAM-Verbindung gekoppelt und arbeiten nach dem Master-/Slave-Prinzip. Dabei werden sämtliche Katalogoperationen (RDCAT, WRCAT, ...) immer vom Master-Server durchgeführt. Der Einsatz von SCA ist deshalb nur für den Master sinnvoll.

Der Vorteil des Shared-Pubsets gegenüber der Shared-Private-Disk liegt im Wesentlichen im geringeren Ein-/Ausgabe-Bedarf bei der Abwicklung von Katalogfunktionen. Es entfallen die F1-Kennsatz-Zugriffe samt zugehörigem Serialisierungs-Mechanismus.

Bei Berücksichtigung folgender Hinweise ist das Performance-Verhalten annähernd gleich wie bei „normalen“ Public-Volumes:

- Derjenige Server, von dem die meisten Zugriffe erfolgen, wird als Master gewählt (Minimierung der serverübergreifenden Aktionen).
- Um den Aufwand für die serverübergreifenden Katalogaktionen in vertretbarem Rahmen zu halten, sollten pro RPF (Relativer Performance Faktor) nicht mehr als zwei OPEN/CLOSE-Operationen pro Sekunde auf dem Slave-Server durchgeführt werden.

Dateien auf Shared-Pubsets können mit DAB von jedem Server aus mit lokalem Caching unterstützt werden.

Private Volumes

Die Speicherplatzverwaltung erfolgt durch den Anwender. Durch exakte Vorgabe der Lage der Dateien auf den jeweiligen Volumes kann der Anwender Zugriffskonflikte bei häufig benutzten Dateien vermeiden.

Bei Dateibearbeitungsaufrufen mit Katalogzugriff ergibt sich eine deutlich höhere Anzahl von Verwaltungs-Ein-/Ausgaben gegenüber Public-Volumes durch zusätzliche Zugriffe auf den VTOC-Bereich (Volume Table of Contents). Z.B. erfolgen pro OPEN/CLOSE-Paar 6 logische Zugriffe auf die F1-Kennsätze mit jeweils einer oder mehreren physikalischen Ein-/Ausgaben pro logischem Zugriff.

Ein günstiges Performance-Verhalten ist also nur dann erzielbar, wenn die Anzahl der Verwaltungs-Ein-/Ausgaben klein ist im Verhältnis zu den Nutz-Ein-/Ausgaben.

Mehrrechnerbetrieb

Bei simultanem Zugriff von mehreren Servern auf dasselbe Private-Volume ist die Konsistenz der VTOC-Einträge wesentlich.
Die Höhe des Koordinierungsaufwands für Dateibearbeitungsaufrufe mit Katalogzugriff bei Shared-Private-Disk hängt stark davon ab, ob ein oder mehrere Server gleichzeitig schreibberechtigt sind.

Shared-Private-Disk (nur an Kanal Typ S, also S-Server und (nicht empfohlen) SX-Server)

Diese Betriebsart muss gewählt werden, wenn zwei oder mehrere Server gleichzeitig schreibberechtigt sind.

Zur Sicherstellung der Datenkonsistenz ist die Serialisierung der Katalogzugriffe erforderlich. Dies geschieht durch:

- Sperren der F1-Kennsätze im VTOC-Bereich bei jedem physikalischen Zugriff
- zusätzliche Einträge in den F1-Kennsätzen über den Status der Dateien

Diese Koordinierung der Verwaltungszugriffe erfolgt direkt auf dem Plattenlaufwerk und ist zeitlich sehr aufwändig.

Beispiel

> Durch die Zusatzinformationen in den F1-Kennsätzen erhöht sich die Anzahl der logischen Zugriffe pro OPEN/CLOSE-Paar auf 10-20. Ein logischer Zugriff erfordert durchschnittlich 2 physikalische Ein-/Ausgaben, wobei vor und nach jeder physikalischen Ein-/Ausgabe zusätzlich eine weitere Ein-/Ausgabe zum Sperren und Freigeben der F1-Kennsätze erforderlich ist.

Um bei Einsatz der Shared-Private-Disk ein gutes Performance-Verhalten zu erreichen, sollten Dateibearbeitungsaufrufe mit Katalogzugriff möglichst nicht zu häufig auftreten.

DRV: Dual Recording by Volume

DRV erhöht die Verfügbarkeit der auf den Platten gespeicherten Information durch doppelte Datenaufzeichnung auf zwei physikalischen Plattenlaufwerken. Dabei erfolgt die Verdoppelung im Ein-/Ausgabesystem von BS2000/OSD.

Bei einer synchronen Schreib-Operation wird zuerst eine asynchrone Ausgabe auf das erste, anschließend eine synchrone Ausgabe auf das zweite Plattenlaufwerk gestartet.

Zur Durchführung einer Lese-Operation wird das Plattenlaufwerk mit der kleineren Warteschlange ausgewählt, wodurch eine unsymmetrische Auslastung der Original-Platte und der Spiegel-Platte entsteht. Durch die Wahl des schwächer ausgelasteten Plattenlaufwerks verkürzt sich die Ein-/Ausgabezeit (Software-Duration) bei lesenden Zugriffen im Vergleich zum SRV-Betrieb (Single Recording by Volume).

Gegenüber dem SRV-Betrieb kann etwa das gleiche Performance-Verhalten erwartet werden.

Kopiergeschwindigkeit

Sowohl bei der Rekonstruktion als auch bei der Egalisierung kann die Kopiergeschwindigkeit pro Pubset dynamisch mit `/SET-DRV-PARAMETER`, Operand `COPY-SPEED=*LOW/*MEDIUM/*HIGH` in drei Stufen eingestellt werden. Bei `COPY-SPEED= *LOW` werden die DRV-Kopieroperationen stark verzögert, sodass der Pubset für Ein-/Ausgaben von Anwendungen besser erreichbar ist. Die Voreinstellung ist `*MEDIUM`.

Kopierumfang

Bei der Rekonstruktion werden nicht alle Blöcke der Platte kopiert, sondern nur noch die im F5-Label als belegt gekennzeichneten Blöcke.
Nach einem Systemausfall oder nach einem abnormal beendeten Pubset-Export führt DRV eine Egalisierung durch, um die Plattenpaare wieder abzugleichen.
Neben den bereits bestehenden Varianten, alle Blöcke oder nur die Systemdaten zu kopieren, bietet DRV die Möglichkeit, nur die Systemdaten und die geöffneten Dateien zu egalisieren. Diese Option ist nur für SF-Pubsets oder Volume-Sets eines SM-Pubsets möglich. Sie kann nur vor dem Importieren des Pubsets bzw. Volume-Sets mit `/SET-DRV-PARAMETER UNIT=*PUBSET(...)/*VOLUME-SET(...), EQUALIZE-DATA= *OPEN-FILES` eingestellt werden.

Schnelle Rekonstruktion nach getrennter Verarbeitung

Bei getrennter Verarbeitung (z.B. Sicherung der Original-Daten, Batch-Verarbeitung der Spiegel-Daten) merkt sich DRV die veränderten Bereiche. Dadurch kann die Rekonstruktionszeit ggf. drastisch verkürzt werden, wenn nur der Änderungsumfang seit Beginn der getrennten Verarbeitung (im Mbyte-Bereich) statt der gesamten Dateien (im Gbyte-Bereich) kopiert werden muss.

Plattenspiegelung

Bei den Plattenspeichersystemen Symmetrix und FibreCAT CX steht das RAID1-Level hardwaremäßig zur Verfügung. Hier erfolgt die doppelte Datenaufzeichnung ohne weitere Software-Unterstützung. Siehe auch Seite 61.

7.2.2 Beschleunigung der Katalogzugriffe mit SCA

SCA (Speed Catalog Access) ist ein empfohlenes Softwareprodukt zur Beschleunigung der Katalogdienste, das beim Suchen von Datei- und Jobvariablen-Einträgen die sequenzielle Suche nach Katalogblöcken durch den direkten Zugriff ersetzt.
Realisiert wird diese Vorgehensweise mit Hilfe von zwei Tabellen. Eine Tabelle gibt Aufschluss über den freien Platz in den Katalogblöcken, die andere ordnet den Datei- bzw. Jobvariablennamen die logische Blocknummer des Katalogblocks zu (Verweistabelle). Beide Tabellen werden von der SCA-Task aufgebaut.

SCA darf nur für SF-Pubsets aufgerufen werden. Bei SM-Pubsets ist der beschleunigte Zugriff auf Katalogeinträge bereits intern realisiert.

SCA wird in zwei Varianten angeboten: mit und ohne Task-Wechsel. Empfohlen wird der Einsatz der Variante „SCA ohne Task-Wechsel“.

- SCA ohne Task-Wechsel

  Die Verweistabelle wird im Klasse-4-Speicher aufgebaut und ist so für alle Tasks erreichbar. Alle SCA-Routinen (außer dem Aufbau der Tabellen) laufen unter der User-Task ab. Der Aufwand für die Task-Wechsel entfällt, der Aufwand für Serialisierungsmaßnahmen ist minimal.

- SCA mit Task-Wechsel

  Die Verweistabelle wird von der SCA-Task in ihrem Klasse-5-Speicher verwaltet. Jede Katalogdienst-Anforderung einer User-Task führt zu einem Task-Wechsel.

Welche Variante für einen Pubset verwendet werden soll, bzw. ob SCA beim Importieren des Pubsets automatisch gestartet werden soll (Standard für BS2000/OSD ab V8.0), kann im MRSCAT-Eintrag hinterlegt werden (Operand `START-SPEEDCAT` in `/ADD-` und `/MODIFY-MASTER-CATALOG-ENTRY`).

Bei Einsatz der Variante „SCA ohne Task-Wechsel“ ist ein CPU-Minderbedarf von ca. 1 - 2 % bei gleichzeitig höherem Klasse-4-Speicherbedarf gegenüber der Variante „SCA mit Task-Wechsel“ zu erwarten.

Automatischer Start von SCA

Wenn SCA installiert ist, dann wird seit BS2000/OSD V8.0 beim Importieren eines Pubsets standardmäßig SCA im Modus *SPEEDCAT-TASK gestartet, um einen performanten Katalogzugriff bei SF-Pubsets zu gewährleisten.

Im Kommando ADD-MASTER-CATALOG-ENTRY wird deshalb seit BS2000/OSD V8.0 der neue Standardwert START-SPEEDCAT=*AUTOMATIC verwendet.

Vorteile durch den Einsatz von SCA

1. Erhöhung des Gesamtdurchsatzes des Servers bei katalogintensiver Last

   Die verminderte Anzahl physikalischer Zugriffe zur Datei TSOSCAT pro logischem Katalogaufruf (OPEN, CLOSE, ...) führt zu einer deutlichen Verkürzung der Katalogzugriffszeit bei gleichzeitiger Verringerung der Systembelastung.

   Weiterhin werden die Plattenlaufwerke entlastet, auf denen sich die Katalogdateien befinden. Bei SF-Pubsets sind das i.d.R. die Volumes xxxx.0. Für das Gesamtsystem bedeutet dies, dass der Durchsatz der User-Tasks erhöht werden kann.
   Die Laufzeit für katalogintensive Programme (z.B. ARCHIVE) sowie das Antwortzeitverhalten bei Kommandos mit hohem Anteil an Katalogzugriffen (z.B. /CREATE-FILE, /MODIFY-FILE-ATTRIBUTES, /IMPORT-FILE) kann erheblich verbessert werden.

   Bei schnellen Servern und Dialogbetrieb ist SCA unabdingbar. Der Einsatz führt zu einer deutlichen Durchsatzsteigerung.

2. Höhere Flexibilität der RZ-Organisation

   Eine der bisherigen organisatorischen Maßnahmen zur Verbesserung der Katalog-Performance kann mit Einsatz von SCA entfallen. Nicht mehr erforderlich ist dann, häufig benutzte Katalogeinträge an den Anfang einer Katalog-Blockkette zu legen.

3. Volle Kompatibilität

   SCA verändert die Katalogstruktur nicht. Damit bleiben die Anwenderschnittstellen wie auch die internen Systemschnittstellen zum Katalogverwaltungssystem erhalten.

Wesentliche Performance-Verbesserungen sind nur zu erwarten, wenn große Katalogbelegungen der Anwender vorliegen (größer 60-100 Datei-Einträge pro Benutzerkennung).

SCA kann für verschiedene Kataloge gleichzeitig gestartet und beendet werden, und zwar entweder automatisch beim Importieren des Pubsets (abhängig vom MRSCAT-Eintrag) oder per Prozeduraufruf (/ENTER-JOB FROM-FILE=SPEEDCAT.ENTER.START) nach dem Importieren des Pubsets.

7.2.3 Einsatz von SF-Pubsets

Für den Ablauf von Anwendungen mit bestimmten Ein-/Ausgabe-Anforderungen ist die Zusammenfassung gleichartiger Public-Volumes zu Pubsets grundsätzlich sinnvoll.

Ein Pubset soll 4 oder weniger Public-Volumes umfassen. Dies hat den Vorteil, dass bei einem Ausfall nur der betreffende Pubset blockiert wird und mit den restlichen Pubsets noch ein eingeschränkter Betrieb weitergeführt werden kann. Das Einrichten eines sogenannten Stand-by-Pubsets (= Kopie des Home-Pubsets) für den raschen Wiederanlauf ist zu empfehlen (Handhabung siehe Handbuch „Einführung in die Systembetreuung“ [11]).

Durch den Einsatz von mehreren SF-Pubsets wird die Vielfalt der Verteilungsmöglichkeiten von Dateien im Sinne eines günstigen Performance-Verhaltens erhöht.

Hinweise zur Verteilung der Systemdateien TSOSCAT, Seitenwechselbereiche und SYSEAM werden im Abschnitt „Einrichten von Systemdateien“ auf Seite 174 gegeben.

Um die Ein-/Ausgabe-Anforderungen der Anwender, die unter verschiedenen Benutzerkennungen arbeiten, durch Systemvorgaben zu verteilen, sind bei `/ADD-USER` bzw. `/MODIFY-USER-ATTRIBUTES` folgende Parameter zu beachten:

```
/ADD-USER USER-IDENTIFICATION=xx, DEFAULT-PUBSET = *HOME / catid        (1)
                                  PUBSET = *HOME / catid                (2)
                                  PUBLIC-SPACE-LIMIT = max / integer    (3)
```

(1) `catid` kennzeichnet denjenigen Pubset, auf dem der Anwender Dateien ohne Angabe einer catid ansprechen kann, z.B. in `/CREATE-FILE`, `/ADD-FILE-LINK`, `/MODIFY-FILE-ATTRIBUTES`.

(2) `catid` gilt für den Pubset, auf den der Anwender zugreifen darf. Der Zugriff zu Dateien eines bestimmten Pubsets ist für einen Anwender nur möglich, sofern er im Benutzerkatalog des jeweiligen Pubsets eingetragen ist.

(3) `max` gibt das Pubspace-Limit für diese Benutzerkennung des unter (2) angegebenen Pubsets an.

Ein Sonderfall ist, wenn für eine Benutzerkennung der Pubspace-Wert Null für einen Pubset vergeben wird: Der Benutzer hat Zugriff auf alle Dateien, deren Zugriffsrechte entsprechend gesetzt sind; er selbst kann jedoch keine Dateien im Home-Pubset einrichten.

7.2.4 Einsatz von SM-Pubsets

Während die Formatierungseigenschaften eines Volume-Sets, die bei der Initialisierung festgelegt werden, über die gesamte Dauer des Bestehens unveränderbar sind, können die Eigenschaften Verfügbarkeit und Performance im laufenden Pubset geändert werden. Im Folgenden sollen nur die Perfomance-Eigenschaften weiter betrachtet werden.

SM-Pubsets aus der Sicht des Anwenders

Mit /CREATE-FILE und /MODIFY-FILE-ATTRIBUTES (Operand STORAGE-CLASS) bzw. dem Makro FILE (Operand STOCLAS) können für eine Datei so genannte Storage-Services angefordert werden:

Operand	Erläuterung
STORAGE-CLASS	Dateiattribute, die für den Ablageort relevant sind
= *STD	Zuordnung der Default-Storage-Klasse aus dem Benutzerkatalog des SM-Pubsets
= <name>	Zuordnung einer bestimmten Storage-Klasse
= *NONE	keine explizite Zuordnung einer Storage-Klasse. Der Anwender legt die Performance-Attribute (*STD / *HIGH / *VERY-HIGH / *USER-MAX) selbst fest.

Informationen über Namen und Eigenschaften der verfügbaren Storage-Klassen (d.h. bei Schutz durch GUARDS muss der Zugriff erlaubt sein) erhält der Anwender über /SHOW-STORAGE-CLASS.

Mit /SHOW-PUBSET-FILE-SERVICES kann sich der Anwender über die Storage-Services der vorhandenen Volume-Sets informieren. Er kann somit kontrollieren, ob es einen Volume-Set mit den für seine Datei gewünschten Eigenschaften gibt.

Die Storage-Services können auch über Direktattributierung angefordert werden.

SM-Pubsets aus der Sicht der Systembetreuung

Damit die Performance-Anforderungen des Anwenders an die Volume-Sets eines SM-Pubsets wirksam werden können, müssen entsprechende Berechtigungen und Speicherplatz-Kontingente in den Benutzerkatalog eingetragen werden (/ADD-USER, /MODIFY-USER-ATTRIBUTES bzw. /MODIFY-USER-PUBSET-ATTRIBUTES):

Operand	Erläuterung
DEF-STORAGE-CLASS = <name>	Default-Storage-Klasse für die Anwender-Angabe STORAGE-CLASS=*STD

Operand	Erläuterung
DMS-TUNING-RESOURCES	für die explizite Anforderung über Direktoperand oder implizit über eine Storage-Klasse:
= *NONE	kein Caching zugelassen
= *CONCURRENT-USE	Anforderung PERFORMANCE=*HIGH
= *EXCLUSIVE-USE	Anforderung PERFORMANCE=*VERY-HIGH
PERM-/TEMP-/WORK-SPACE-LIMIT = *PARAMETERS(...)	Speicherplatz-Kontingente der Anwender festlegen (jeweils für permanente, temporäre und Arbeitsdateien):
HIGH-PERF-SPACE= ...	für hochperformanten Speicherplatz
VERY-HIGH-PERF-SPACE= ...	für sehr hochperformanten Speicherplatz

Mit /CREATE- bzw. /MODIFY-STORAGE-CLASS richtet die Systembetreuung Storage-Klassen ein bzw. ändert sie.
Indem der Anwender einer Datei eine Storage-Klasse zuordnet, erhält diese Datei implizit alle in der Storage-Klasse festgelegten Performance-Attribute.

Operand	Erläuterung
PERFORMANCE	bestimmt das Caching-Verhalten (Hauptspeicher, GS):
= *STD	keine Cache-Nutzung
= *HIGH	Caching mit Verdrängung nach LRU
= *VERY-HIGH	Caching ohne Verdrängung
USAGE	erhöhte Performance-Anforderungen gelten:
= *READ-WRITE	für Lese- und Schreiboperationen
= *READ	nur für Leseoperationen
= *WRITE	nur für Schreiboperationen
DISK-WRITE	legt den Zeitpunkt der Datenkonsistenz fest:
= *IMMEDIATE	Datenkonsistenz nach jeder Schreiboperation (Voraussetzung: nichtflüchtiges Cache-Medium)
= *BY-CLOSE	Datenkonsistenz erst nach CLOSE-Verarbeitung
= *STD	für permanente Dateien gilt *IMMEDIATE, für temporäre Dateien gilt *BY-CLOSE
VOLUME-SET-LIST	bestimmt die Zuordnung einer Volume-Set-Liste
= <name>	Name der Liste
= *NONE	keine Zuordnung

Zur Erfüllung der erhöhten Performance-Anforderungen (*HIGH / *VERY-HIGH) muss von der Systembetreuung die Zuweisung des Cache-Mediums Haupt- oder Globalspeicher erfolgen (/MODIFY-PUBSET-CACHE-ATTRIBUTES; siehe Abschnitt „User-PFA-Caching“ auf Seite 203).

Durch die Angabe einer Volume-Set-Liste pro Storage-Klasse lassen sich RZ-spezifische Strategien zur Steuerung der Ein-/Ausgabe-Verteilung realisieren. Ordnet ein Anwender einer Datei eine Storage-Klasse mit angeschlossener Volume-Set-Liste zu, wird die Datei bevorzugt auf einem zur Liste gehörigen Volume-Set angelegt.
Die Definition einer Volume-Set-Liste erfolgt mit /CREATE-VOLUME-SET-LIST.

Die Performance-Eigenschaften eines Volume-Sets werden mit /MODIFY-PUBSET-DEFINITION-FILE festgelegt:

Operand	Erläuterung
PERFORMANCE	bestimmt das Caching-Verhalten (Hauptspeicher, GS):
= *STD	keine Cache-Nutzung
= *HIGH	Caching mit Verdrängung nach LRU
= *VERY-HIGH	Caching ohne Verdrängung
= list-poss(3) ...	Werteliste ermöglicht einen Performance-Bereich
WRITE-CONSISTENCY	legt den Zeitpunkt der Datenkonsistenz fest:
= *IMMEDIATE	Datenkonsistenz nach jeder Schreiboperation (Voraussetzung: nichtflüchtiges Cache-Medium)
= *BY-CLOSE	Datenkonsistenz erst nach CLOSE-Verarbeitung

Die ausreichende Beschreibung des Performance-Profils ist Voraussetzung für das Funktionieren der Volume-Set-Selektion. Das Performance-Profil wird nicht automatisch aus der physikalisch vorhandenen Konfiguration ermittelt. Es ist die Aufgabe der Systembetreuung, die realen Verhältnisse (Berücksichtigung eines flüchtigen oder nichtflüchtigen Cache-Mediums bei der Vergabe von WRITE-CONSISTENCY) richtig zu beschreiben.

7.2.5 Einrichten von Systemdateien

Systemdateien werden vom Betriebssystem zur Abwicklung seiner Aufgaben benötigt. Wegen dieser exponierten Stellung zählen sie, was die Leistungsfähigkeit eines IT-Systems betrifft, zu den sensitivsten Dateien. Aus der Vielzahl der Systemdateien wird auf die folgenden am häufigsten zugegriffen:

Funktion	DVS-Name
Dateikatalog (SF-Pubset) Dateikatalog (SM-Pubset)	`$TSOS.TSOSCAT` `$TSOS.TSOSCAT.<volset-id>`
Seitenwechselbereiche	`$TSOS.SYS.PAGING.<vsn>`
Hintergrundspeicher für die Zugriffsmethode EAM	`$TSOS.SYSEAM`

Bei der Einrichtung dieser Dateien ist das Hauptaugenmerk auf die **Vermeidung von Zugriffskonflikten** zu legen.

Primär lässt sich die Wahrscheinlichkeit von Zugriffskonflikten durch die Aufteilung der Dateien auf mehrere Volumes verringern. Befinden sich aus wirtschaftlichen Gründen (z.B. Nutzung der Plattenkapazität) Anwender- und Systemdateien auf demselben Volume, so ist die Zusammenlegung mit schwach frequentierten Anwenderdateien anzustreben.

Als charakteristische Merkmale der Systemdateien sind die **Dateigröße** und die **Zugriffshäufigkeit** anzusehen.

Wenn ein System eingerichtet ist, kann die Lage der Seitenwechselbereiche nur mit hohem Aufwand verändert werden. Deshalb muss bereits beim Konfigurieren besonderes Augenmerk auf Lage und Größe dieser Systemdatei gerichtet werden.

Bei Programmentwicklungen ist die Häufigkeit der Zugriffe auf katalogisierte Modulbibliotheken (TASKLIBs) und Makrobibliotheken oft so groß, dass beim Konfigurieren deren Lage berücksichtigt werden muss.

7.2.5.1 Dateikatalog (SF-Pubset)

Auf den Dateikatalog (die Datei TSOSCAT) wird nur von den Routinen des CMS (Catalog Management System) zugegriffen. Die PAM-Blöcke dieser Datei enthalten entweder:

- Dateieinträge
- Jobvariableneinträge
- globale Verwaltungsdaten
  (MRS-Katalog und Einträge zur Beschreibung des aktuellen Zustands des TSOSCAT)

Die Zugriffe auf die Datei erfolgen blockweise. Durch den Systemparameter BMTNUM (siehe Seite 363) oder /IMPORT-PUBSET bzw. /ADD- und /MODIFY-MASTER-CATALOG-ENTRY wird festgelegt, wie viele Ein-/Ausgabe-Puffer das CMS zur Verfügung hat. Simultananforderungen der Anwender auf denselben Katalogblock werden mit Hilfe einer „Buffer Management Table“ (BMT) und einer Börse synchronisiert (je eine BMT und eine Börse pro Katalog-Ein-/Ausgabe-Puffer).

Die Katalogdatei kann in mehrere Bereiche gegliedert sein. Aus technischen Gründen muss der erste Bereich auf dem Volume xxxx.0 liegen. Sind mehrere Pubsets vorhanden, gibt es auf jedem Pubset einen Katalog. Vermieden werden muss, dass Teile von TSOSCAT auf stark belasteten Plattenlaufwerken liegen. Als solche gelten u.a. alle Volumes mit Seitenwechselbereichen und SYSEAM-Bereichen.

Dateikatalogformate

Es gibt drei Dateikatalogformate:
NORMAL und LARGE (implizit, für Pubsets mit „großen“ Objekten) sowie EXTRA LARGE.

TSOSCAT-Typ	max. Größe (Katalogblöcke)	max. Größe (PAM-Seiten)	kompatibel zu
NORMAL	8.192	16.384	BS2000/OSD-BC V1.0
LARGE	16.384	32.368	BS2000/OSD-BC V5.0
EXTRA LARGE	32.368	64.016	BS2000/OSD-BC V6.0B

Die Katalogformate LARGE und EXTRA LARGE sind inkompatibel:
Werden sie für einen Pubset genutzt, so ist mit diesem Pubset ein Rückstieg in eine ältere BS2000-Version nicht mehr möglich.

Für SM-Pubsets mit Katalogen des Typs EXTRA LARGE können für jeden der Spezialkataloge #MIN, #JVC und #PTV bis zu 100 Teilkataloge mit jeweils 64.016 PAM-Seiten angelegt werden (/ADD-CATALOG-FILE).

Das CMS erkennt, wenn ein Dateikatalog zu 90% belegt ist, und nimmt automatisch eine Katalogvergrößerung vor, sofern das ohne Wechsel des Katalogformats möglich ist.
Für Spezialkataloge des Typs EXTRA LARGE wird dann ein neuer Teilkatalog angelegt, wenn keiner der bereits existierenden Teilkataloge vergrößert werden kann.

Außerdem kann die Datei manuell mit dem Kommando /MODIFY-FILE-ATTRIBUTES (Operand SPACE) vergrößert werden. Die Veränderung wird sofort wirksam und nicht erst nach dem nächsten Import des Pubsets.

Einrichten des TSOSCAT

Die Größe des TSOSCAT wird bestimmt durch

- die Anzahl der zugelassenen Anwender
  (repräsentiert durch die mit /ADD-USER eingetragenen Benutzerkennungen)
- die Anzahl der Dateien und Jobvariablen im System
- die Größe der Katalogeinträge, die bei Dateien von der Anzahl ihrer Extents, bei Jobvariablen von der Größe des JV-Werts abhängt
- das Zersplittern der Katalogeinträge, das durch selektives Löschen entsteht
  (Der Platz, der durch Löschen „einzelner“ Einträge frei wird, steht zwar zum Anlegen neuer Einträge zur Verfügung, bleibt aber sonst ungenutzt. Erst nach dem Löschen aller Einträge wird ein Katalogblock freigegeben.

Die Einträge im TSOSCAT sind in Katalogblöcken (zu je 4 KB) abgelegt:

- Ein Katalogblock für Dateien, der so genannte „Primary Block“, wird für jeden Benutzer auch dann reserviert, wenn er keine Dateien anlegt.
- Ein Katalogblock enthält nur Dateieinträge eines Benutzers oder nur JV-Einträge eines Benutzers.
- In einen Katalogblock passen 1 bis 13 Dateieinträge.
  Auf einem ausreichend großen und mit SPACEOPT gepflegten Pubset kann im Durchschnitt mit 10 Dateieinträgen pro Katalogblock gerechnet werden.
- In einen Katalogblock passen 8 bis 18 JV-Einträge.
  Ein Durchschnitt lässt sich nur schwer angeben, weil die Größe der JV-Werte durch den Benutzer frei gewählt werden kann. Beispielsweise passen bei MONJVs, die eine Standardgröße von 128 Byte haben, 11 JV-Einträge in einen Katalogblock.

Die durchschnittliche Anzahl der durch „Primary Blocks“ und Dateieinträge belegten Katalogblöcke lässt sich durch folgende Formel abschätzen:

$$\text{Anzahl Katalogblöcke} = \text{Anzahl Benutzerkennungen} + \frac{\text{Gesamtanzahl Dateien}}{10}$$

Die Formel berücksichtigt die Zersplitterung der Katalogeinträge und die sinkende Kapazität bei steigender Größe der Einträge.
Für Jobvariablen werden zusätzliche Katalogblöcke benötigt.

Beispiel

Berechnung der Kataloggröße für 150 Benutzerkennungen mit 65 Dateien pro Benutzerkennung: $\text{TSOSCAT} = 150 + \frac{150 \bullet 65}{10} = 1125 \text{ Katalogblöcke}$

Ohne das Softwareprodukt SCA (Speed Catalog Access) sollten pro Benutzerkennung nicht mehr als 65 Dateien bzw. Jobvariablen katalogisiert werden. Mit SCA kann die Anzahl der Dateien bzw. Jobvariablen höher sein.

Lage des TSOSCAT

Beim Einrichten des Systems wird standardmäßig auf dem Volume xxxx.0 ein TSOSCAT in der Größe von 2000 PAM-Blöcken eingerichtet.

Unter der Voraussetzung, dass der auf Systemresidenz (xxxx.0) eingerichtete Seitenwechselbereich **im späteren Betrieb nicht benutzt wird**, sollte der TSOSCAT in seiner erforderlichen Größe auf dem Volume xxxx.0 angelegt werden (bei Installation mit SIR).

Wird das Volume xxxx.0 neben den Anwenderaktivitäten (max. 15% Auslastung) von der Systemseite her im Wesentlichen nur durch Katalogzugriffe belastet (ebenfalls max. 15% Auslastung), so schafft es bei 70% Read-Hit-Rate ca. 50 Katalog-Ein-/Ausgaben pro Sekunde. Eine Reduzierung durch die Erhöhung der Anzahl CMS-Ein-/Ausgabe-Puffer und dem Einsatz von SCA ist anzustreben.

Bei Einsatz mehrerer Pubsets befindet sich der TSOSCAT automatisch auf jedem Pubset. Die Empfehlungen gelten dann sinngemäß für das Volume xxxx.0 jedes Pubsets.

Nach Aufnahme des Echtbetriebs wird die Überprüfung der Anzahl Katalog-Ein-/Ausgaben pro Sekunde mit SM2 empfohlen (Reports „CMS Queues“, „CMS IO'S“ der Reportgruppe CATALOG-MANAGEMENT).

Für den Produktivbetrieb sind bei der Kalkulation der Leistung des CMS neben der Katalog-Ein-/Ausgabe-Intensität auch der Adressraumbedarf für Tabellen und Puffer sowie Behinderungen als Folge von Synchronisation zu beachten. Beim Einsatz von mehreren Pubsets werden Katalog-Ein-/Ausgabe-Puffer und deren Verwaltungstabellen (BMT) pro Pubset angelegt. Bei vielen Pubsets kann deshalb der Adressraumbedarf des CMS erheblich ansteigen.

Mit /ADD-, /MODIFY-MASTER-CATALOG-ENTRY und /IMPORT-PUBSET ist die pubset-spezifische Festlegung der Anzahl CMS-Puffer möglich.

Beispiel

Bei der Systeminstallation wurden die Systemparameter BMTNUM=32 und CATBUFR=N angegeben. Für 2 Pubsets benötigt CMS damit als Arbeitsbereich:

(33 • (4096 + 178) + 388) • 2 = 282.860 Bytes, d.h. 277 KB Klasse-4-Speicher

- Anzahl Pubsets
- Zentrale Arbeitstabelle des CMS
- BMT- und DVS-Zugriffstabellen
- Katalogblock-Ein-/Ausgabe-Puffer
- Anzahl Ein-/Ausgabe-Puffer des CMS + 1

Für Pubsets mit EXTRA LARGE Katalogen wird ein zusätzlicher Ein-/Ausgabepuffer für den statischem MRS-Katalog (ca. 4 KB) benötigt.

Zum Schutz simultaner Anforderungen wird pro Katalogpuffer eine Börse angelegt. Zum Schutz gegen konkurrierende Aufrufe der CMS-Routinen werden darüber hinaus weitere Börsen benutzt.

Um die Pfadlängen beim Suchen von Datei- und Jobvariablen-Einträgen kurz zu halten und bei diesem Suchen möglichst wenige Katalogpuffer gegen Simultanaufrufe anderer Anwender zu sperren, muss von Zeit zu Zeit die Belegung der Platten mit Dateien und der Katalogblöcke mit Datei- und JV-Einträgen reorganisiert werden. Dabei müssen alle Dateien und Jobvariablen gesichert, gelöscht und wieder eingerichtet werden. Beim Wiedereinrichten sind zwei eventuell gegenläufige Forderungen zu optimieren:

1. Zum einen sollten große Dateien zuerst wieder ins System übernommen werden. Denn dann kann deren Verteilung nach Gesichtspunkten der Zweckmäßigkeit durchgeführt werden. Kleine Dateien können auf Lückenplätzen untergebracht werden.
2. Zum anderen wird die Leistung des CMS effizient genutzt, wenn Dateieinträge von hochfrequentierten Dateien möglichst am Anfang der Kette von Katalogblöcken jeder Benutzerkennung liegen. Das CMS beginnt die Suche nach Datei- oder JV-Einträgen jeweils im ersten Block der Anwender-Katalogblock-Kette.

Der zweiten Forderung ist der Vorrang zu geben.
Gibt es zu viele Benutzerkennungen und Datei- und JV-Einträge pro Benutzerkennung, sollte das Softwareprodukt SCA eingesetzt werden (Details siehe Abschnitt „Beschleunigung der Katalogzugriffe mit SCA“ auf Seite 168).

7.2.5.2 Dateikatalog (SM-Pubset)

Ein SM-Pubset besteht aus einem Control-Volume-Set und mehreren „normalen“ Volume-Sets.

Der Dateikatalog eines SM-Pubsets ist so auf die einzelnen Volume-Sets verteilt, dass jeder Teilkatalog die Informationen für die Dateien auf dem entsprechenden Volume-Set enthält.

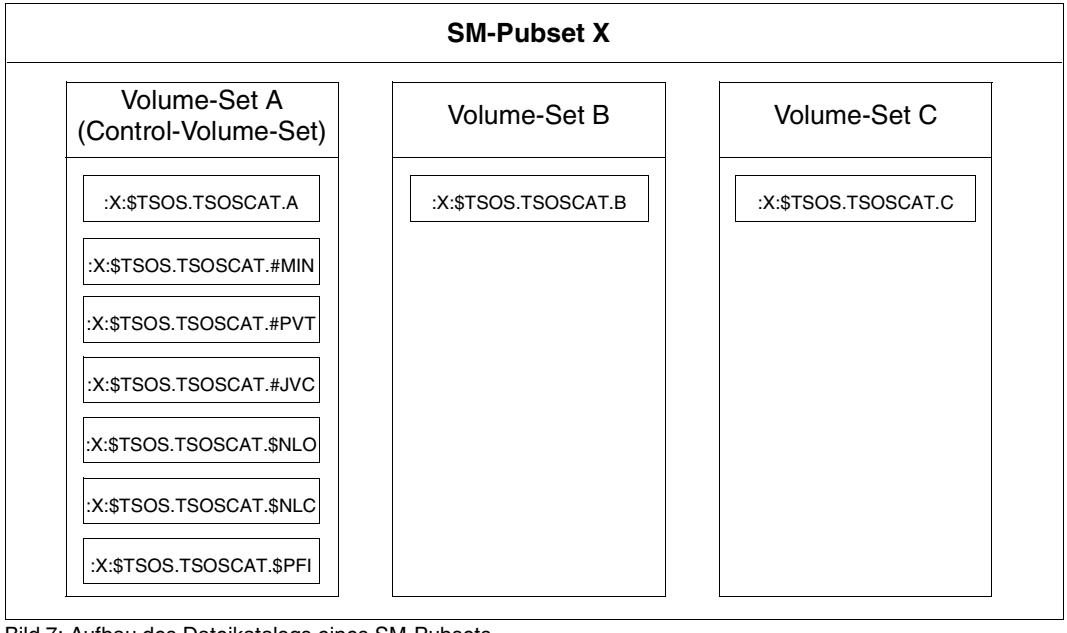

Bild 7: Aufbau des Dateikatalogs eines SM-Pubsets

Bei einer Zusammenlegung mehrerer SF-Pubsets zu einem SM-Pubset ist darauf zu achten, dass bei der Systemgenerierung die Werte für die CMS-Puffer angepasst werden. Bei einfacher Addition der Werte wird sich i.A. durch den besseren Ausgleich von Lastschwankungen am Katalog eine bessere Katalog-Performance ergeben.

Die weiteren globalen Teilkataloge für

- migrierte und leere Dateien
- Dateien auf privaten Datenträgern
- Jobvariable

liegen auf dem Control-Volume-Set und sollten dort auf mehrere Volumes aufgeteilt werden. Weitere Teilkataloge auf dem Control-Volume-Set ($NLO, $NLC, $PFI) dienen ausschließlich der Datensicherheit.

Der zentrale Benutzerkatalog liegt ebenfalls auf dem Control-Volume-Set.

Die einzelnen Teilkataloge entsprechen im Aufbau dem TSOSCAT eines SF-Pubsets. Für die Einrichtung dieser Teilkataloge gelten daher die gleichen Empfehlungen wie für die Einrichtung des TSOSCAT auf SF-Pubsets.

Der Einsatz von SCA ist nicht möglich, der beschleunigte Katalogzugriff ist bereits intern realisiert.

7.2.5.3 Seitenwechselbereiche

Seitenwechselbereiche werden als Dateien unter folgendem Namen katalogisiert:
`:<catid>: $TSOS.SYS.PAGING.<vsn>`

Bei jedem Systemlauf kann über den Parameterservice eine Auswahl aus der Menge aller existierenden Seitenwechseldateien getroffen werden. Damit ist eine Anpassung an unterschiedliche Lastprofile von Session zu Session möglich.

Alle Pubsets, die für den kommenden Systemlauf mindestens einen Seitenwechselbereich enthalten, müssen bereits vor dem Einleiten des Systems (Startup) online sein. Sie werden vom Startup exklusiv belegt, jedoch nicht implizit importiert (d.h. die Seitenwechselbereiche werden benutzt, auch wenn der Pubset nicht importiert ist). Diese Pubsets können während des Systemlaufs von anderen BS2000-Systemen (im Sinne von „Shared-Pubsets“) nicht verwendet werden.

Seitenwechselbereiche dürfen auch auf SM-Pubsets liegen.

Einrichten der Seitenwechselbereiche

Beim Einrichten eines Pubsets werden auf allen für Seitenwechsel vorgesehenen Volumes dieses Pubsets die Seitenwechsel-Dateien reserviert und für jede ein Eintrag im Dateikatalog dieses Pubsets angelegt. Ein Volume kann nur eine Seitenwechsel-Datei (allerdings mit mehreren Extents) enthalten.

Die Größe des Seitenwechselbereichs hängt von der Anzahl und der virtuellen Programmgröße der Programme ab, die gleichzeitig ablaufen. Hinzu kommt der jeweils generierte Systemadressraum.

Für die Erstellung wird folgende Formel empfohlen:

```
Benötigte Größe = (Anzahl Anwender • virt. Programmgröße + Systemadressraum) • 2
```

Nach Aufnahme des Echtbetriebs sollte eine Überprüfung (Report „Paging Area Utilization“ der Reportgruppe MEMORY von SM2) erfolgen, um die tatsächlich benötigte Dateigröße festzustellen.

Für die gleichzeitig ablaufenden Programme sollte die Größe des Seitenwechselbereichs ein Mehrfaches des mittleren Bedarfs, jedoch nicht mehr als das Doppelte des maximalen Bedarfs betragen:

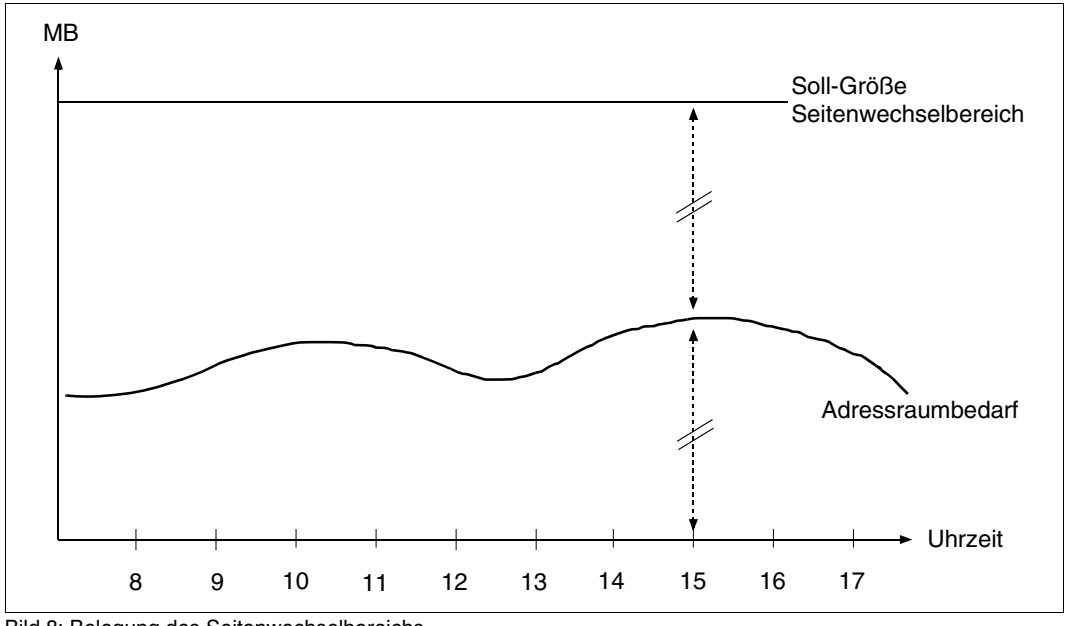

Bild 8: Belegung des Seitenwechselbereichs

Die **Zugriffshäufigkeit** zum Seitenwechselbereich ist abhängig von:

- der Betriebsart (TP-, Dialog- oder Batch-Betrieb)
- der Größe des Hauptspeichers
- der Geschwindigkeit des Servers

Dialogbetrieb

Der Dialogbetrieb ist charakterisiert durch viele, vom Working-Set-Bedarf her aber relativ kleine Tasks (50 - 150 4-KB-Seiten).
Da auf die einzelne User-Task i.d.R. nur wenige Seitenanforderungen pro Dialogschritt entfallen (5 - 10), ergibt sich auch bei einer höheren Paging-Gesamtrate keine wesentliche Beeinträchtigung der Leistung, die der einzelne Anwender sieht.

Die Durchführung des Paging-Vorgangs ist aber nicht nur mit einer zeitlichen Verzögerung, sondern auch mit einem Systemaufwand verbunden.

Aus Effizienzgründen sollte der Aufwand für Paging 3% der Leistungsfähigkeit des Servers nicht überschreiten. Bei leistungsstärkeren Servern ist selbst dieser Prozentsatz zu hoch und erfordert eine unwirtschaftlich hohe Anzahl von Volumes mit Seitenwechselbereichen.

TP-Betrieb

Der TP-Betrieb ist gekennzeichnet durch wenige, vom Working-Set-Bedarf aber relativ große Tasks (mehrere MB groß).

Zur Erfüllung einer gewünschten Anwenderfunktion werden viele Seiten angesprochen, oft über mehrere Tasks hinweg (speziell bei DB/DC-Anwendungen).

Eine höhere Paging-Gesamtrate führt hier meist zu einer schweren Beeinträchtigung der Leistung, die der einzelne Anwender sieht. Wegen der hohen Seitenanforderungen zur Erfüllung einer Funktion steigt die Paging-Rate schon bei geringem Hauptspeicher-Mangel stark an. In diesem Betriebspunkt genügt eine geringfügige weitere Lasterhöhung, um einen Leistungseinbruch hervorzurufen (exponentieller Anstieg der Paging-Rate: das System „kippt“).

Der TP-Betrieb reagiert auf Hauptspeicher-Mangel wesentlich empfindlicher als die anderen Betriebsarten. Daher müssen die Richtwerte für die obere Grenze der Paging-Rate entsprechend tiefer liegen (siehe Abschnitt „Richtwerte für die BS2000/OSD-Server“ auf Seite 353).

Vom wirtschaftlichen Standpunkt aus ist stets die Senkung der Paging-Rate auf Werte unterhalb der angegebenen Richtwerte anzustreben.

Um auch auf plötzliche Überlasten besser reagieren zu können, sollte ein Volume, welches ausschließlich für Paging-Aktivitäten verwendet wird, nur zu maximal 10% ausgelastet sein. Dabei schafft es bei 70% Read-Hit-Rate ca. 30 Paging-Ein-/Ausgaben pro Sekunde. Da normalerweise nicht mehr als 10 - 20 Paging-Ein-/Ausgaben durchgeführt werden sollen (siehe Abschnitt „Richtwerte für die BS2000/OSD-Server“ auf Seite 353), ist es i.d.R. nicht nötig die Paging-Area auf mehr als 3 bis 6 physikalische Geräte aufzuteilen.

Lage der Seitenwechselbereiche

Seitenwechseldateien sollten auf allen Volumes die gleiche Größe haben (möglichst nur ein Extent), um eine gleichmäßige Ein-/Ausgabe-Auslastung aller Volumes zu erreichen. In der Regel korreliert die Ein-/Ausgaberate mit der Größe der Seitenwechseldatei.

Nach Möglichkeit sollte kein Seitenwechselbereich auf Volumes aktiviert werden, auf denen sich der Dateikatalog oder ein SYSEAM-Bereich befindet. Dies gilt auch für Volumes, die durch Anwenderdateien hoch ausgelastet sind.

Weitere Einzelheiten sind im Handbuch „Einführung in die Systembetreuung“ [11], Abschnitt „Speicherverwaltung“, und im Handbuch „Systeminstallation“ [31], Abschnitt „Behandlung wichtiger Systemdateien“, beschrieben.

Beispiel zur Berechnung von Größe und Verteilung der Seitenwechselbereiche

Annahme

TP-Betrieb:	1200 Benutzer in über 30 UTM-Tasks und 5 Datenbank-Tasks mit einer jeweiligen durchschnittlichen Programmgröße von 120 MB
Systemadressraum:	240 MB
CPU:	S140-10C
Plattentyp:	Symmetrix DMX-3
Paging-Rate:	maximal 100 Ein-/Ausgaben pro Sekunde Wie auf Seite 182 erläutert, sollte ein Paging-Volume nicht mehr als 30 Paging-Ein-/Ausgaben durchführen, d.h. (3) - 4 Volumes mit Seitenwechselbereichen sind erforderlich

Berechnung

```
(35 * 120 MB + 240 MB) * 2 = 8880 MB
```

Zur Erreichung einer gleichmäßigen Volume-Belastung muss eine Aufteilung in gleich große Teilbereiche erfolgen, d.h. 2220 MB pro Volume.

Auswahl bestimmter Volumes für den Seitenwechsel zum Startup-Zeitpunkt

Ohne Auswahl der Seitenwechselbereiche über den Parameterservice werden die auf dem Home-Pubset eingerichteten Bereiche verwendet.

Durch Angaben in der Systemparameterdatei wird festgelegt, welche Seitenwechselbereiche für den kommenden Systemlauf tatsächlich benutzt werden sollen. Wenn durch die Lastplanung des IT-Systems das Lastprofil bereits vor der Systemeinleitung bekannt ist, können die Paging-Parameter nach diesem Profil mit der Parameterdatei realistisch eingestellt werden.
Grundsätzlich sollte auf dem jeweils ersten Volume eines Pubsets (VSN=xxxx.0) kein Seitenwechselbereich reserviert werden, weil auf diesem immer der pubsetspezifische Dateikatalog liegt und ggf. vom CMS her eine hohe Ein-/Ausgaberate zu erwarten ist.

Erweiterung und Reduzierung des Seitenwechselbereichs

Der Seitenwechselbereich kann sowohl erweitert als auch reduziert werden. Damit ist die Verlagerung des Seitenwechselbereiches von dem performance-kritischen Home-Pubset auf einen weniger belasteten Pubset möglich. Weitere Informationen können dem Abschnitt „Seitenwechelbereich (Paging-Area)“ im Handbuch „Einführung in die Systembetreuung“ [11] entnommen werden.
Zur Erweiterung des Seitenwechselbereiches bzw. Reduzierung der Paging-Aktivitäten auf ausgewählten Volumes siehe Kommandobeschreibungen zu `/EXTEND-PAGING-AREA` und `/MODIFY-PAGING-AREA-ATTRIBUTES` (Handbuch „Kommandos“ [16]).

7.2.5.4 SYSEAM-Datei

Die Datei SYSEAM dient der Speicherung von temporären Daten (Zugriffsmethode EAM). Sie kann auf jedem Pubset eingerichtet werden.

Benutzer greifen auf die SYSEAM-Datei zu, die auf ihrem Benutzer-Default-Pubset liegt. Ist auf dem Benutzer-Default-Pubset keine SYSEAM-Datei vorhanden, so erfolgen die Zugriffe auf die SYSEAM-Datei des Home-Pubsets.

Die optimale Größe von SYSEAM kann nur nach Beobachtung der mittleren Belegung während eines ausreichend langen Zeitraums ermittelt werden (Hinweise zur Ersterstellung siehe im Anhang „Performance-relevante Systemparameter“, Parameter EAMMEM, EAMMIN, EAMSEC, EAMSIZ, ab Seite 370).
Die Beobachtung wird mit dem Programm SPCCNTRL (Space Control) durchgeführt. An die Datei SYSEAM werden – besonders bei interaktiver Programmentwicklung im Dialogbetrieb – hohe Anforderungen gestellt. Häufige Übersetzungsläufe beeinflussen sowohl die Größe als auch die Zugriffshäufigkeit beträchtlich.

Für die Überwachung der Zugriffshäufigkeit wird der Einsatz von SM2 empfohlen (Dateiüberwachung).

Lage der Datei SYSEAM

Damit bei einer größeren Anzahl von Anwendern, zusammen mit leistungsstarken Servern, die Datei SYSEAM nicht zum Engpass wird, ist die Aufteilung auf mehrere Pubsets sinnvoll.

Nach Möglichkeit sollten keine SYSEAM-Bereiche auf Volumes gelegt werden, auf denen sich Seitenwechselbereiche befinden.

Da beim Plattenspeichersystem Symmetrix sämtliche Ein-/Ausgabe-Anforderungen dem Caching unterliegen (Write-Hit = 100%), ist die Aufteilung der Datei SYSEAM auf mehrere Volumes innerhalb eines Pubsets nicht erforderlich.

Eine starke Beanspruchung der Datei SYSEAM ist meist mit einer entsprechenden Größe der Datei gekoppelt. Es empfiehlt sich in diesen Fällen, die erforderlichen Volumes ausschließlich für SYSEAM zu reservieren und hinsichtlich der Ein-/Ausgaberate bis an die obere Grenze der Auslastung (30%) zu gehen. In diesem Fall schafft ein Volume ca. 300 Ein-/Ausgaben pro Sekunde.

Lastspitzen für SYSEAM

Als Hauptanwender von SYSEAM sind die Compiler, das Softwareprodukt LMS sowie die Binder BINDER und DBL anzusehen.

Der Systembetreuung sollten die Zeiten bekannt sein, zu denen Programmdienste aufgerufen werden. Dann können Entscheidungen getroffen werden, ob zusätzliche Pubsets einzurichten und wann diese zu importieren sind.

Bei Lasten mit großem Anteil an Programmdiensten sollten die TSOS-Makrobibliotheken, die Anwender-Makrobibliotheken und die MODLIB-Dateien nicht auf Volumes liegen, auf denen es auch SYSEAM-Bereiche gibt.

Steht genügend Hauptspeicher zur Verfügung, so ist es sinnvoll, mit Hilfe des Systemparameters EAMMEM (siehe im Anhang „Performance-relevante Systemparameter“, Seite 370) einen Teil des SYSEAM-Bereiches in den Klasse-4-Speicher zu legen (gilt nur für den Home-Pubset) und damit SYSEAM-Ein-/Ausgaben zu sparen. Übersetzungs- und Binderläufe können damit entsprechend beschleunigt werden.

Maßnahmen nach SYSEAM-Secondary-Allocation

Wenn in einem Systemlauf die Konsolmeldung

```
DMS0852 (&00): (&01) PAM SEITEN UND (&02) EXTENTS
```

ausgegeben wird (mit `&00` als Name der SYSEAM-Datei), dann überschreitet die Dateigröße den Wert von EAMMIN bzw. den pubsetspezifischen Eintrag für MINIMAL-SIZE im MRSCAT.

Diese Meldung, die bei jeder Erweiterung oder Reduzierung ausgegeben wird, sollte nur bei Lastspitzen auftreten. Tritt diese Meldung häufig auf, so ist dies ein Hinweis, dass der Systemparameter EAMMIN bzw. der Wert für MINIMAL-SIZE im MRSCAT-Eintrag zu klein gewählt wurde. Zur Vermeidung von Secondary-Allocations müssen diese Parameter angepasst und die Datei entsprechend erweitert werden. Die Dateien können nach der Systemeinleitung gelöscht und wieder neu eingerichtet werden. Zu diesem Zeitpunkt dürfen keine Benutzer auf die SYSEAM-Dateien zugreifen. Ein erneuter Startup ist danach nicht erforderlich.

Durch einen System-Kaltstart werden die SYSEAM-Dateien auf die Größe des Systemparameters EAMMIN zurückgesetzt.

7.2.5.5 Meldungsdateien

Um das Erzeugen und Ausgeben von Systemmeldungen in BS2000/OSD effizient zu gestalten, sind zwei Gesichtspunkte zu beachten:

- Verwaltung der Meldungen

  Alle Meldungen, die bei jedem Einsatz des Systems gebraucht werden könnten, sind in mehreren ISAM-Dateien abgelegt. Beim Startup werden die für den Systemlauf unbedingt benötigten und die lt. Parameter vorgegebenen Meldungsdateien verfügbar gemacht (Systemparameter `MSGFILii` und `MSGNOFL`, siehe im Anhang „Performance-relevante Systemparameter“, Seite 369). Meldungsdateien, die nur beim Startup (nach dem Laden des MIP-Subsystems) gebraucht werden, können in der MIP-Parameterdatei (`SYSPAR.MIP.<version>`) angegeben werden.
  Im Systemlauf können weitere Meldungsdateien hinzugenommen oder entfernt werden.

- systeminterne Behandlung der Meldungen

  Jede mit dem Softwareprodukt MSGMAKER erzeugte Meldungsdatei enthält den Meldungstext und einige Attribute (zum Suchen des Meldungstextes) sowie die Bedeutung und den Antworttext (für `/HELP-MSG-INFORMATION`).

Beim Bereitstellen wird die Datei eröffnet und der Verwaltungsteil in einen Arbeitsbereich im Klasse-4-Speicher eingelesen.
Wenn Anwender aufgrund ihrer Verarbeitung Anforderungen zur Ausgabe von Systemmeldungen stellen, so werden bei der Behandlung dieser Meldungsausgaben folgende Aktionen durchgeführt:

- Prüfung aufgrund des mitgelieferten Meldungsschlüssels, ob die Meldung bereits im Meldungspuffer steht oder ob sie mit dem ISAM-Zugriff GETKY gelesen werden muss.
- Prüfung aufgrund des Meldungsgewichts (Weight-Code), ob diese Meldung auf das Ausgabemedium ausgegeben werden muss oder ob sie zu unterdrücken ist.
- Aktualisierung variabler Textteile und Einleitung der Ausgabe (falls keine Unterdrückung gefordert wird). Dabei ist mindestens ein Task-Wechsel notwendig.

Ausgabemedien können sein:

- die Haupt- und/oder Nebenbedienstation
- und/oder SYSOUT/SYSLST der User-Task
- und/oder ein User-Bereich (Puffer)
- oder eine spezielle BCAM-Applikation (z.B. OMNIS)

Jede angeforderte Meldungsausgabe an die Haupt- und/oder Nebenbedienstation (auch solche, deren Ausgabe zu unterdrücken ist) wird außerdem als Datensatz in die CONSLOG-Datei geschrieben.

Einrichten von Meldungsdateien

In Systemläufen, die nur solche Systemerweiterungen aufrufen, die keine eigenen Meldungsdateien benötigen, sind zwei Meldungsdateien im Einsatz. Diese werden im Startup-Parameterservice festgelegt. Für weitere Anforderungen werden die benötigten Systemerweiterungen und deren Meldungsdateien ins System übernommen.

Dieses Übernehmen kann nach unterschiedlichen Gesichtspunkten durchgeführt werden:

- Meldungsdateien, die nur bei speziellen Anwendungen benötigt werden, sollten nicht auf den Platten des Home-Pubsets stehen (sie belegen dort nur unnötig Platz), sondern auf dem zu diesen Anwendungen gehörenden Pubset. Für den aktuellen Bedarf können die Platten mit `/IMPORT-PUBSET` zugeschaltet oder die Dateien aus Sicherungsbeständen (z.B. mit HSMS) rekonstruiert werden. Die Meldungsdateien werden dann mit `/MODIFY-MSG-FILE-ASSIGNMENT` oder `/MODIFY-MIP-PARAMETERS` in das laufende System übernommen.
- Einzelne Meldungen (oder die Inhalte ganzer Meldungsdateien) werden in die für den Systemlauf notwendigen Meldungsdateien integriert.

Anzahl der Meldungsdateien

Im Allgemeinen können die Meldungen spezieller Softwareprodukte

- in der zum Softwareprodukt mitgelieferten Meldungsdatei verbleiben oder
- in andere Meldungsdateien integriert werden.

Wieviele Meldungsdateien als Bestandteil des Gesamtsystems verwaltet und welche davon in welchen Systemläufen verfügbar gemacht und eventuell nach Ende des Bedarfs entfernt werden, liegt im Ermessen der Systembetreuung.

Wenige zusätzliche Meldungsdateien vereinfachen deren Verwaltung und benötigen weniger Systemadressraum. Bei vielen Meldungsdateien ist eine genauere Anpassung an den aktuellen Lastfall möglich.

Vorschläge zur Verringerung bzw. Beschleunigung der Meldungsausgabe

1. Unterdrücken bestimmter Systemmeldungen

   Das Bereitstellen, Aktualisieren und Ausgeben von Meldungen ist für den ordnungsgemäßen Systemablauf notwendig, stellt aber auch eine Belastung für das System dar. Die Art der Behandlung der Meldungen soll dem Bedarf angepasst sein. Zum Beispiel kann bereits die Anforderung zur Meldungsausgabe abgeschaltet werden, wenn das Laden von Programmen (`/START-EXECUTABLE-PROGRAM`) für die Tätigkeit des Operators ohne Bedeutung ist und auch sonst ein Protokoll dazu nicht ausgewertet wird (Systemparameter EACTETYP auf 0 setzen, siehe Seite 369).

   Werden im IT-Betrieb unterschiedliche Anwendungen zeitlich nacheinander abgewickelt, sollte auch die Menge der zu unterdrückenden Ausgaben auf den Bedienstation dem Einzelfall angepasst werden.

   Dazu gehört:

   Alle Meldungen, die hinsichtlich der Ausgabeunterdrückung unterschiedlich zu behandeln sind, werden in ihren Meldungsdateien mit unterschiedlichen Meldungsgewichten versehen. Mit `/ADD-CONSOLE-FILTER` wird für jeden Lastfall die jeweils günstigste Filterstufe eingestellt. Mögliche Lastfälle sind z.B. Produktiveinsatz, Programmentwicklung, Testbetrieb, Diagnose nach Störfällen oder Versionsumstellungen und Mischformen.

   Folgende Empfehlungen sollten beachtet werden:

   Unnötige Ausgaben auf den Bedienstation belasten das System und machen das Protokoll unübersichtlich. Ein einmal erstelltes Konzept für die Vergabe und das Setzen der Meldungsgewichte in die einzelnen Meldungssätze macht sich im Laufe der Zeit bezahlt.

   Zur Ausgabeunterdrückung anhand des Meldungsgewichtes gibt es eine Alternative durch den Einsatz der Funktion Meldungsbestellung bzw. Meldungsabbestellung (`/MODIFY-MSG-SUBSCRIPTION`, `/SET-MSG-SUPPRESSION`). Hiermit ist es einer Meldungsempfängerinstanz möglich, einzelne Meldungen zu bestellen bzw. abzubestellen. Beide Möglichkeiten können auch kombiniert genutzt werden:

   a) Zuerst legt man über die Zuordnung von Berechtigungsschlüsseln und die Festlegung von Meldungsgewichten die Meldungsmenge grob fest.

   b) Dann führt man über den Meldungsbestell-/abbestell-Mechanismus eine Feineinstellung durch.

2. Gezielte Ausgabe von Systemmeldungen

   Zur Vergabe von Berechtigungsschlüsseln (Parameterservice, Anweisung `SET-CODE`) gilt:

   – Mit entsprechenden Berechtigungsschlüsseln können Bedienstationen Bedienungsmeldungen empfangen.

   – Das Durchreichen von Meldungen wird über einen systeminternen Verständigungsmechanismus (mit Hilfe von Börsen) abgewickelt und verursacht einen nicht unerheblichen Systemaufwand.

   – Bei der Vergabe der Berechtigungsschlüssel sollte grundsätzlich geprüft werden, welche Meldungen bzw. Kommandos an den Bedienstationen zur Verfügung stehen müssen, um durch eine restriktive Vergabe überflüssige Meldungen zu vermeiden.

   – Durch den Einsatz des Meldungsbestell-/abbestell-Mechanismus kann eine Optimierung der Meldungszustellung erreicht werden.

3. Beschleunigung der Meldungsausgabe mit DLAM (Dynamic Loadable Access Method)

   Die Systembetreuung kann für jede Meldung das DLAM-Kennzeichen setzen, das im Inhaltsverzeichnis jeder Meldungsdatei hinterlegt ist. Beim Startup wird für alle Meldungsdateien, die laut Startparameter bei „System Ready“ zur Verfügung stehen sollen (Systemparameter MSGFILii, siehe Seite 369), das Inhaltsverzeichnis ausgewertet und in den Bereichszuordnungen (im zentralen Tabellenwerk des Message-Handlers) abgelegt. Danach werden alle Meldungen mit dem DLAM-Kennzeichen aus den jeweiligen Dateien gelesen.

   ```
   Dienstprogramm MSGMAKER
   Anweisung/Maske: ADD-MSG und MODIFY-MSG
   ```

   Vorteil

   Während des Systemlaufs ändert sich der Bedarf an Adressraum für gepufferte Meldungstexte nicht (statisches Bild ab Startup). Bei gesetztem DLAM-Kennzeichen verkürzen sich die Pfadlängen, da die Prüfung entfällt, ob ein gerade benötigter Meldungstext bereits gepuffert ist. Die physikalische Input-Operation wird aus dem Systemlauf in den Startup-Abschnitt vorverlegt:
   Der Aufbau der Meldungen erfolgt im Klasse-5-Speicher zum Startup-Zeitpunkt. Es wird keine physikalische Ein-/Ausgabe bei Aufruf der Meldung während des Systemlaufs durchgeführt.

   Aufwand

   Das Selektieren und Kennzeichnen der einzelnen Meldungen kostet Bearbeitungszeit. Auf großen Servern mit hohem Durchsatz ist DLAM zu empfehlen.

4. Beschleunigung der Meldungsausgabe mit LOCAL-DLAM (Local Dynamic Loadable Access Method)

   Falls eine Meldung mit der Zugriffsmethode LOCAL-DLAM (vergeben mit dem Softwareprodukt MSGMAKER) versehen ist, wird sie bei Aktivierung in den Klasse-4-Speicher kopiert.

   Vorteil

   Wie beim Zugriff mit DLAM ist keine physikalische Ein-/Ausgabe nötig. Zusätzlich fällt der Zugriff auf die zentrale MIP-Task weg, alle Aktionen laufen unter der Auftraggeber-Task ab. Damit wird nicht nur der Systemaufwand reduziert, sondern es werden zusätzlich mögliche Lock-Situationen zwischen der zentralen MIP-Task und anderen Auftraggeber-Tasks verhindert.

5. Beschleunigung der Meldungsausgabe mit Hilfe der Systemparameter MSGCENTL und MSGCENTN (siehe Seite 369)

   MSGCENTL legt die max. Länge von Meldungen, MSGCENTN die Anzahl der Meldungen fest, die im Klasse-4-Speicher zwischengespeichert werden, um Dateizugriffe zu sparen.

   Die Größe des benötigten Klasse-4-Speichers errechnet sich mit:

   ```
   G  = MSGCENTL • MSGCENTN [Bytes]
   ```

7.2.6 Einrichten von Anwenderdateien

Anwenderdateien werden i.A. von den Anwendern im Verlauf ihrer Verarbeitung eingerichtet und bearbeitet. Dabei ist zu beachten, dass jedes Einrichten und Löschen einer Datei, jedes Eröffnen und Schließen einer Datei und jedes Verändern der Größe einer Datei den Dateikatalog belastet.

Wesentliche Kriterien für die Wahl des Datenträgers bzw. der logischen Betriebsart sind die Dateigröße, die Zugriffshäufigkeit und die Katalogintensität im Rahmen der Dateibearbeitung.

Seit BS2000/OSD V8.0 beträgt die Ein-/Ausgabegröße beim Kopieren von Dateien mit `/COPY-FILE` 128 KByte (davor: 64 KByte). Beim Kopieren großer Dateien ergeben sich damit Verbesserungen von bis zu 20% beim CPU-Bedarf und bis zu 15% bei der Laufzeit.

Bei kleinen Dateien kann sich die Laufzeit erhöhen. Beim Einsatz von SCA (siehe Seite 168) verbessert sich die Laufzeit um ca. 5%.

Dateigröße und Zugriffshäufigkeit

Die Zugriffshäufigkeit auf Dateien hat bei der Konzeption der Datenbestände erheblichen Einfluss auf die Leistung des Systems.

- Um die Auslastung der Volumes möglichst gering und gleichmäßig zu halten, sollten zugriffsarme (große) Dateien auf Volumes gelegt werden, auf denen bereits zugriffsintensive Dateien installiert sind und umgekehrt.
- Generell sollten stark frequentierte Dateien auf getrennte Volumes verteilt werden (insbesondere bei schreibintensiven Anwendungen). Dies ist nur sinnvoll bei Anwendungen mit mehreren Tasks.
- Ein- und Ausgabedateien, die innerhalb einer Verarbeitung abwechselnd angesprochen werden, sollten auf getrennten Volumes liegen.
- Auf Private-Volumes kann der Anwender die Lage der Dateien durch explizite Vorgaben festlegen. Auf Public-Volumes können dies nur die Systembetreuung bzw. ausgewählte Anwender (`/MODIFY-USER-ATTRIBUTES`, Operand `PHYSICAL-ALLOCATION`) tun. Die Lage großer Dateien sollte nach Möglichkeit durch explizite Vorgaben festgelegt werden.
- Für zugriffsintensive Dateien zeitkritischer Anwendungen ist die Nutzung dieser Dateien als HIPERFILEs sinnvoll (siehe Abschnitt „Arbeiten mit HIPERFILEs“ auf Seite 195).
- In der Regel werden Lasten mit normalen bis hohen Schreibraten durch die gängigen Caching-Mittel in den Plattensteuerungen gut bewältigt. Bei Lasten mit sehr hohen Schreibraten auf einzelne Hotspots/Dateien kann es aber zu Staus kommen („Write delay“).

Zur Bewältigung dieses Effektes gibt es folgende Tuning-Möglichkeiten, die auch miteinander kombiniert werden können:

– durch den Einsatz von Hiperfiles auf Globalspeicher lassen sich kürzeste Ein-/Ausgabezeiten mit maximalem Durchsatz realisieren (siehe auch Seite 195)

– durch Verteilung der Hotspots auf mehrere logische Volumes bzw. physikalische Geräte lässt sich die Ein-/Ausgabe-Bandbreite vervielfachen. Dazu gibt es

  a) Hardware-Maßnahmen:
  Einsatz von RAID1/0 oder RAID5 (siehe Seite 62) mit zusätzlicher Software-Unterstützung durch den Einsatz von PAV (siehe Seite 69) und

  b) Software-Maßnahmen:
  durch Verteilung des Hotspots bzw. der Datei auf mehrere Dateien, Extents oder Volumes. Als Beispiel sei hier die Verteilung der KDCFILE von openUTM auf mehrere Dateien erwähnt (siehe Seite 213).

Katalogintensität

Wie schon im Abschnitt „Logische Betriebsarten von Platten“ (ab Seite 163) erwähnt, ist der systeminterne Aufwand für Dateibearbeitungsaufrufe mit Katalogzugriff für Public-Volumes bzw. Pubsets am geringsten, gefolgt von Private-Volumes. Am höchsten ist der Aufwand für Shared-Private-Disk.
Der Durchsatz bei den einzelnen logischen Betriebsarten hängt also ab vom Verhältnis der Verwaltungs-Ein-/Ausgaben zu den Nutz-Ein-/Ausgaben.

Für Dateien mit hoher Katalogintensität (Prozeduren, ENTER-Dateien, viele rasch aufeinanderfolgende OPEN-/CLOSE-Operationen) sind Public-Volumes bzw. Pubsets am besten geeignet.

Dateien mit geringer Katalogintensität können auf Private-Volumes gespeichert werden.

Beim gemeinsamen Zugriff von mehreren Servern ist hohe Katalogintensität nur bei Shared-Pubsets vertretbar.

Die Beachtung folgender Hinweise führt zur Reduzierung der Anzahl der Verwaltungs-Ein-/Ausgaben:

- Primary- und Secondary-Space-Zuweisungen (Primary-/Secondary-Allocation) bei `/CREATE-FILE` sollten an die erwartete Dateigröße angepasst werden.
- Unnötiges Löschen und Einrichten einer Datei sollte verhindert werden (Job-Kommandofolgen: `/CREATE-FILE`, `/DELETE-FILE`, `/CREATE-FILE` auf denselben Dateinamen).
- Mit OPEN-/CLOSE-Operationen sollte sparsam umgegangen werden.
  (Auch die Kommandos `/COPY-FILE`, `/CALL-PROCEDURE`, `/INCLUDE-PROCEDURE`, `/ENTER-JOB`, `/ENTER-PROCEDURE`, `/START-(EXECUTABLE-)PROGRAM`, `/LOAD-(EXECUTABLE-)PROGRAM` und `/ASSIGN-SYSDTA` lösen OPEN-/CLOSE-Operationen aus.)

Reorganisation

Bei größeren Systemen empfiehlt sich eine regelmäßige Reorganisation des gesamten Dateibestandes (z.B. alle 3 Wochen). Die Reorganisation wirkt der Zersplitterung von Dateien in viele kleine Extents entgegen. Die Reorganisation wird durch das Softwareprodukt SPACEOPT wesentlich vereinfacht.

SPACEOPT bereinigt die Fragmentierung durch optimale Verlagerung der Datei-Extents auf den Volumes eines Pubsets. Die Reorganisation von Dateien ist auch dann möglich, wenn der verfügbare freie Platz kleiner ist als die Größe der Datei, d.h. SPACEOPT ermöglicht auch lokale Verbesserungen auf Basis des verfügbaren freien Plattenspeichers (Erweiterung in SPACEOPT V5.0 (BS2000/OSD V8.0)).

SPACEOPT kann in RAID-Plattenspeichersystemen (Symmetrix und FibreCAT CX) die Größe von BS2000-Volumes an die Größe der LUNs (Logical Units), durch die sie realisiert werden, anpassen.
Eine derartige Anpassung kann nach einer Plattenmigration mit DRV bei der Quell- und Zielplatte die gleiche Kapazität haben müssen, erforderlich werden. Informationen zur Plattenmigration, z.B. von D3475 nach D3435, finden Sie im Handbuch „DRV“ [8].

Ein weiterer Anwendungsfall ist die Vergrößerung eines BS2000-Volumes im Anschluss an die Vergrößerung einer LUN durch Hinzufügen zusätzlicher Platten im Plattenspeichersystem Symmetrix oder FibreCAT CX. Die Funktion ist nur für das Platten D3435 (FBA-Plattenformat) verfügbar.

SPACEOPT arbeitet volume-bezogen, d.h. Aufträge können für einzelne oder alle Volumes eines Pubsets spezifiziert werden. SPACEOPT bietet Möglichkeiten zur Bewertung des Belegungs- und Fragmentierungszustandes und kann im laufenden Betrieb eingesetzt werden.

SPACEOPT kann eine Verlagerung von Dateien auch dann vornehmen, wenn die Dateien geöffnet sind.

Zweckmäßigerweise erfolgt der Einsatz von SPACEOPT in betriebsärmeren Zeiten, da abhängig vom Fragmentierungsgrad der Volumes eine höhere Ein-/Ausgabe-Last anfallen kann.

Die Performance anderer BS2000-Gastsysteme oder anderer Server, die Ein-/Ausgaben auf die gleiche physikalische Platte ausführen, kann bei der Reorganisation mit SPACEOPT negativ beeinflusst werden.
Siehe dazu auch Abschnitt „Konfigurierung in BS2000/OSD“ auf Seite 66.

Ausführliche Informationen zu SPACEOPT finden Sie im Handbuch „SPACEOPT“ [30].

7.3 Arbeiten mit HIPERFILEs

Ziel des HIPERFILE-Konzepts (High Performant Files) ist die Beschleunigung von Dateizugriffen und die Vermeidung bzw. Beseitigung von Ein-/Ausgabe-Engpässen durch Zwischenpufferung der Daten im Haupt- oder Globalspeicher mit dem Softwareprodukt DAB (Disk Access Buffer).

DAB (Disk Access Buffer) hat das Ziel, die Zugriffe auf Plattendateien durch Caching in den schnellen Speichermedien Hauptspeicher oder Globalspeicher zu beschleunigen.

Der Hauptspeicher ist ein flüchtiges Speichermedium, das sich in erster Linie für das Caching von Lesezugriffen sowie zusätzlich für Schreibaufträge auf temporäre Dateien eignet. Nicht gesicherte Schreibdaten im Zwischenpuffer sind bei einem flüchtigen Speichermedium nach einem Systemabbruch verloren.
Der Globalspeicher (an S-Servern verfügbar) ist ebenfalls ein flüchtiges Speichermedium, das aber durch optionale Erweiterungen (Batterie bzw. unterbrechungsfreie Stromversorgung) zu einem nichtflüchtigen Speichermedium aufgerüstet werden kann. Der Globalspeicher eignet sich daher besonders für ausfallsicheres, schnelles Schreiben.

Mit ADM-PFA-Caching und User-PFA-Caching gibt es zwei Ausprägungen des HIPERFILE-Konzepts:

- ADM-PFA-Caching (Administrator controlled Performant File Access)

  bezeichnet eine Variante des HIPERFILE-Konzepts, bei der die Systembetreuung über Kommandos festlegt, welche Dateien bzw. Volumes in welchem Cache-Medium gepuffert werden sollen und welcher Caching-Modus (Read-, Write- oder Read-Write-Mode) dabei angewendet wird.

- User-PFA-Caching (User controlled Performant File Access)

  bezeichnet eine zweite Variante des HIPERFILE-Konzepts, die die Einbettung der HIPERFILEs in das Data-Management (DVS) beinhaltet. Hier kann der Anwender entscheiden, welche seiner Dateien eines Pubsets HIPERFILEs werden und damit von einem, von der Systembetreuung eingerichteten Cache profitieren sollen.

Darüber hinaus können im Globalspeicher Platten emuliert werden, deren Zugriffszeiten gegenüber dem Plattenspeichersystem Symmetrix erheblich kleiner sind. Die Verwaltung dieser Platten-Emulation wird vom Subsystem GSVOL (GS-Volumes im GS) geleistet.

7.3.1 Caching-Modi

Befinden sich die Daten, auf die zugegriffen wird, im Cache, so spricht man von einem Cache-Hit, andernfalls von einem Cache-Miss. Das Verhältnis der Hits zur Gesamtanzahl der Zugriffe wird als Cache-Hit-Rate bezeichnet. Je höher die Hit-Rate ist, desto mehr Nutzen bringt ein Cache. Hier wird der Cache im Haupt-/Globalspeicher betrachtet; der im Plattenspeichersystem Symmetrix integrierte Cache arbeitet „unsichtbar“ im Hintergrund.

Folgende Caching-Modi stehen zur Verfügung (die Lesezugriffe sind in den Bildern jeweils links, die Schreibzugriffe jeweils rechts durch Pfeile gekennzeichnet):

Read-Cache

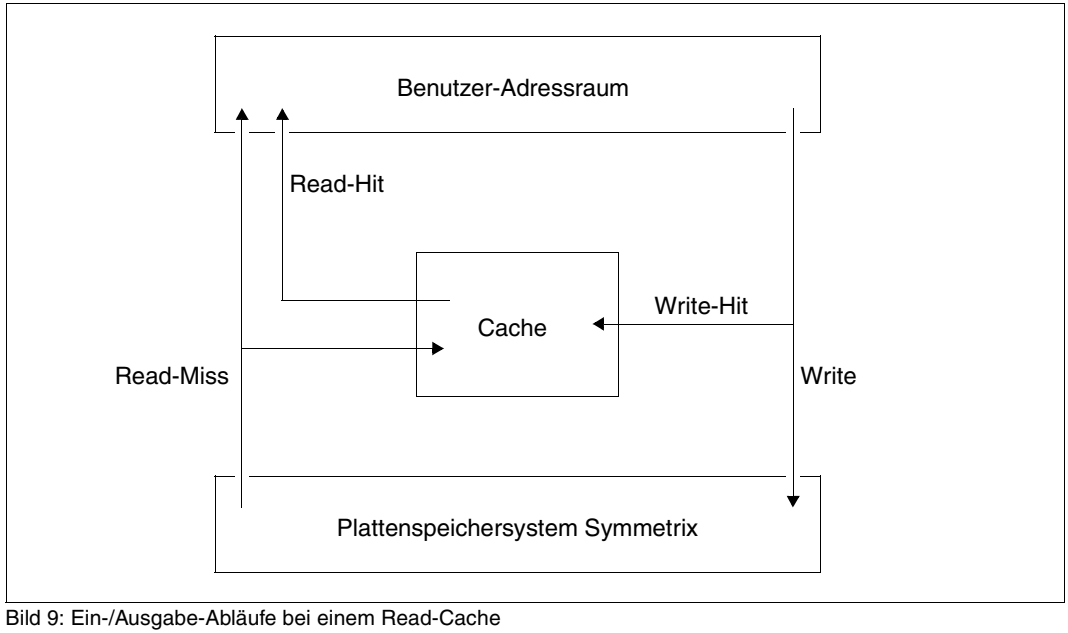

Bild 9: Ein-/Ausgabe-Abläufe bei einem Read-Cache

Read-Hit: Die Daten befinden sich zum Zugriffszeitpunkt im Cache und werden von dort gelesen.

Read-Miss: Die Daten werden vom Symmetrix-System gelesen und gleichzeitig in den Cache eingetragen, damit nachfolgende Lesezugriffe von dort befriedigt werden können.

Write: Schreibzugriffe erfolgen grundsätzlich auf das Symmetrix-System. Befindet sich der entsprechende Datenblock bereits im Cache („Write-Hit“), wird der Inhalt aktualisiert, ohne dass der Schreibvorgang beschleunigt wird.

Write-Cache

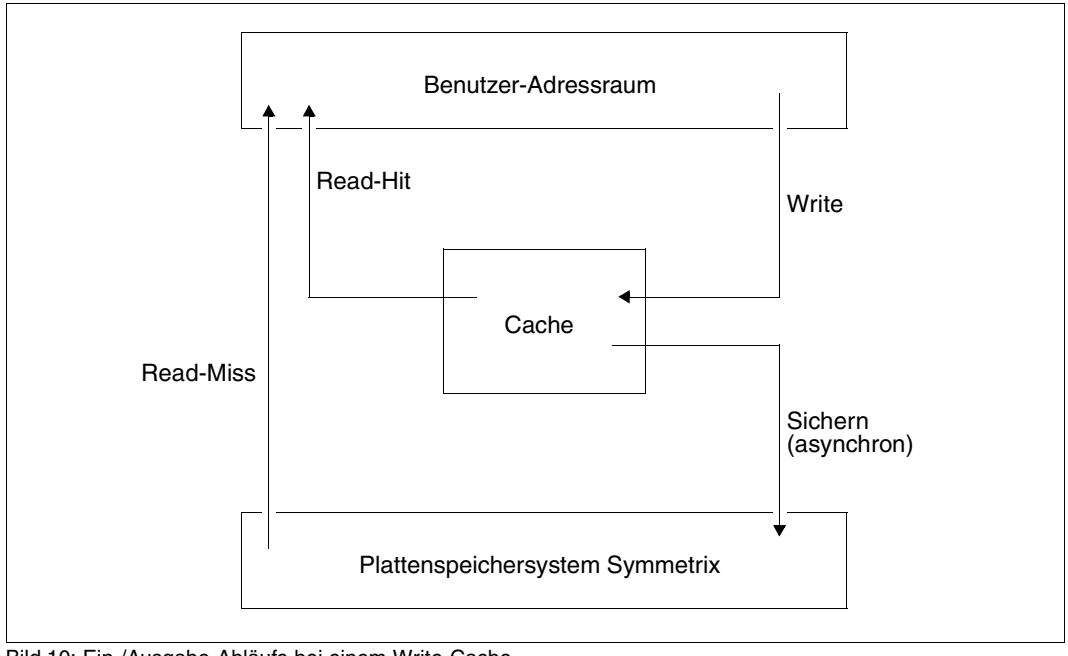

Bild 10: Ein-/Ausgabe-Abläufe bei einem Write-Cache

Read-Hit: Der Lesezugriff erfolgt direkt aus dem Cache (wie beim Read-Cache).

Read-Miss: Die Daten werden vom Symmetrix-System gelesen, jedoch nicht in den Cache eingetragen.

Write: Sowohl beim Haupt- als auch beim Globalspeicher wird immer in den Cache geschrieben, unabhängig davon, ob der Datenblock dort vorhanden ist oder nicht. Für die Anwendung ist der Ausgabevorgang beendet, sobald die Daten im Cache stehen. Das Schreiben auf das Symmetrix-System wird i.d.R. unmittelbar danach angestoßen.

Read-Write-Cache

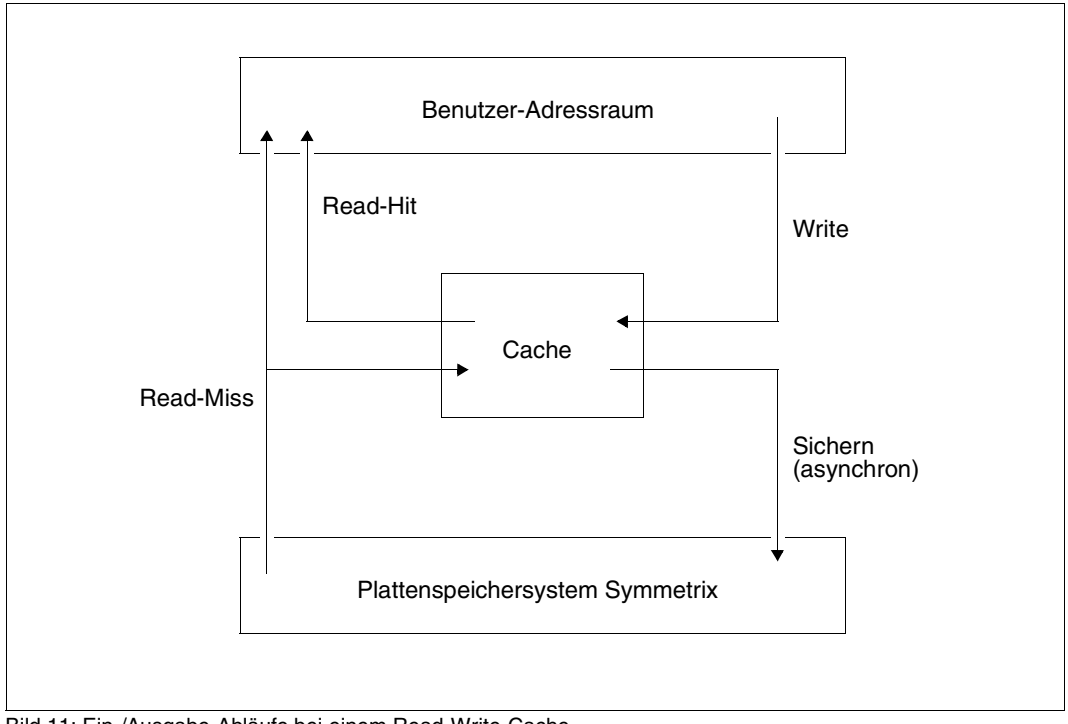

Bild 11: Ein-/Ausgabe-Abläufe bei einem Read-Write-Cache

Read-Hit: wie Read-Cache

Read-Miss: wie Read-Cache

Write: wie Write-Cache

7.3.2 ADM-PFA-Caching

Beim **ADM-PFA-Caching** steuert die Systembetreuung die Einrichtung von Cache-Bereichen und die Zuordnung von ausgewählten Datenbereichen (ein Cache-Bereich ist stets ein Teilbereich eines gesamten Cache-Speichers, der eine eigene Verwaltungseinheit darstellt). Mit `/START-DAB-CACHING` kann die Systembetreuung voneinander unabhängige Cache-Bereiche einrichten und damit ausgewählte Daten verschiedener Anwendungen gegeneinander abschotten. Auch für ganze Volumes kann ein Cache-Bereich eingerichtet werden. Eine ausführliche Beschreibung ist im Handbuch „DAB“ [6] zu finden.

Mit dem Begriff **AutoDAB** wird eine Variante des DAB-Cachings bezeichnet, bei der zum einen durch automatische und intelligente Verfahren die Systemverwaltung bei der Administrierung des Cachings entscheidend entlastet wird, und zum anderen dadurch auch die Effektivität des DAB-Cachings nochmals gesteigert werden kann.
Ein DAB-Cache-Bereich kann entweder als „automatischer“ oder „nicht-automatischer“ Cache-Bereich eingerichtet werden.

Für die Nutzung des Cache-Bereichs kann eine der drei folgenden Möglichkeiten eingestellt werden:

a) Der berechtigte Anwender spezifiziert, welche Dateien mit welchem Cache-Modus den eingerichteten Cache-Bereich nutzen sollen.

b) Der Systemverwalter legt fest, dass alle Anwender-Dateien eines Pubsets den Cache-Bereich nutzen.

c) Der Systemverwalter richtet einen automatischen Cache-Bereich ein, bei dem die optimale Auswahl der zu unterstützenden Dateien automatisch erfolgt. Diese Auswahl wird permanent überwacht und ggf. korrigiert. Mit AutoDAB können auch ganze Pubsets durch einen Cache-Bereich abgedeckt werden.

DAB verwaltet jeden Cache-Bereich in Form von so genannten Cache-Segmenten. Die Standardgröße eines Cache-Segmentes beträgt bei automatischen Cache-Bereichen 32 KB. Sie kann auch bei nicht automatischen Cache-Bereichen von der Systembetreuung mit 4, 8, 16 oder 32 KB festgelegt werden (das automatische Caching muss während der Änderung gestoppt werden).

Beim ersten Lesezugriff auf einen mit DAB unterstützten Bereich (Datei) werden von DAB mit Seitenkettung benachbarte Datenblöcke, deren Anzahl von der eingestellten Cache-Segmentgröße abhängt, vom Symmetrix-System gelesen.

Räumliche Lokalität

Bei Lesezugriffen mit guter räumlicher Lokalität (vor allem bei sequenziellen Zugriffen) ermöglichen große Segmente (= 32 KB) einen so hohen Durchsatz von Ein-/Ausgabe-Aufträgen, dass in diesem Fall eine große Anzahl von Read-Hits auftritt und sich gleichzeitig die Zugriffe auf das Symmetrix-System auf ein Minimum reduzieren.

Bei Lesezugriffen mit geringerer räumlicher Lokalität (Random-Zugriff, im Datenbank-Betrieb die zumeist benutzte Zugriffsart) empfiehlt es sich, kleine Segmente (= 4 KB) zu wählen.
AutoDAB erkennt gute Lokalität und führt bei guter Lokalität automatisch einen Prefetch durch (auch wenn ein kleineres Cache-Segment eingestellt wurde).

Zeitliche Lokalität

Die in den Cache eingelesenen Blöcke bleiben im Cache stehen, bis DAB beendet oder dieser Speicherbereich für ein anderes Cache-Segment benutzt wird.
Verdrängungen werden nach dem LRU-Prinzip (Least Recently Used) verwaltet, wodurch bei guter zeitlicher Lokalität der Zugriffe schon mit einem relativ kleinen Cache-Bereich eine hohe Read-Hit-Rate ereicht werden kann.
Für performance-kritische Anwendungen, deren Lesezugriffe eine schlechte zeitliche Lokalität aufweisen, bietet DAB die Möglichkeit der residenten Zwischenpufferung.

Schreibaufträge werden bei einem Read-Write-Cache (bzw. Write-Cache) in jedem Fall direkt in den Cache eingetragen, unabhängig davon, ob der Datenblock bereits im Cache ist oder nicht. Für die Anwendung ist der Ausgabevorgang beendet, sobald die Daten in den Cache geschrieben sind. Die Daten werden von DAB zu einem späteren Zeitpunkt auf das Symmetrix-System gesichert.

Um mit DAB das Cache-Medium Globalspeicher nutzen zu können, müssen DAB-Partitionen im Globalspeicher eingerichtet werden (siehe Handbücher „Einführung in die Systembetreuung“ [11] und „DAB“ [6]).

Bei Verwendung des Cache-Mediums Hauptspeicher ist zu beachten, dass DAB die Systempuffer im Hauptspeicher resident anlegt, d.h. der Hauptspeicher muss entsprechend dimensioniert sein.

Mit den folgenden Kommandos steuert die Systembetreuung den Einsatz von ADM-PFA-Caching mit DAB:

Kommando	**Funktion**
START-DAB-CACHING	Cache-Bereiche attributieren und einrichten
SHOW-DAB-CACHING	Informationen über die aktuelle DAB-Konfiguration und Zugriffszähler (Hit-Raten) ausgeben
STOP-DAB-CACHING	Cache-Bereiche auf Platte sichern und auflösen
MODIFY-DAB-CACHING	Parameter eines DAB-Cache-Bereichs dynamisch ändern
FORCE-STOP-DAB-CACHING	Auflösung eines DAB-Cache-Bereichs ohne Sicherung der Schreibdaten durchführen

Einsatzempfehlungen

- Genereller Einsatz von AutoDAB

  Die Auswahl der zu puffernden Datenbasis und die Einstellung des Prefetching-Faktors sollte durch das automatisierte Caching erfolgen. Es ist deshalb empfehlenswert, die performance-kritischen Datenträger oder Pubsets mit AutoDAB zu bedienen.
  Im Regelfall ist die folgende Vorgehensweise einfach und zielführend:

  1. Bestimmung aller performance-kritischen Anwendungen
  2. Bestimmung aller Volumes/Pubsets, die von diesen Anwendungen angesprochen werden
  3. Zusammenfassung aller dieser Volumes/Pubsets zu einem automatischen ADM-PFA-Cache-Bereich (günstig für den Fall, dass über die Zugriffsintensität auf einzelne Pubsets nichts Näheres bekannt ist)
     oder
     Definition eines automatischen PFA-Cache-Bereichs für jedes einzelne Pubset (siehe auch Abschnitt „User-PFA-Caching“ auf Seite 203)

- Festlegung der Cache-Bereich-Größe

  Die Größe des Cache-Bereichs sollte mindestens 1 % der Größe der zu unterstützenden Datenbasis (parallel bearbeitete Dateien) betragen. Bei überwiegend sequenzieller Verarbeitung kann dieser Wert unterschritten werden, bei überwiegend Random-Verarbeitung ist dieser Wert u.U. zu klein. Ist der Cache zu klein gewählt, so wird dies von AutoDAB als Konsolmeldung mitgeteilt.

- Beschleunigung aller Schreibzugriffe:

  Unabhängig von der Lokalität beschleunigt DAB bei einem Read-Write-Cache (bzw. Write-Cache) alle Schreibzugriffe, solange freie Puffer zur Verfügung stehen.
  Damit lassen sich kurzzeitige Lastspitzen abfangen und schnelle Dateizugriffszeiten erreichen. Da die im Cache zwischengelagerten Schreibdaten aber von DAB auf das Symmetrix-System gesichert werden müssen, ist bei Schreibanwendungen nur bei ausreichend hoher Lokalität der Zugriffe eine Entlastung des Ein-/Ausgabe-Systems möglich.

- Home-Pubset

  Der Home-Pubset kann nicht mit PFA in den DAB-Cache-Medien Haupt- und Globalspeicher zwischengepuffert werden.Dies ist mit ADM-PFA-Caching zwar möglich, sollte aber entweder nur mit reinem Read-Cache erfolgen oder im nichtflüchtigen Globalspeicher mit Schreib-Cache nur für solche Dateien, auf die vor „System Ready“ nicht zugegriffen wird.

- SM-Pubsets

  Daten eines SM-Pubsets können nicht mit ADM-PFA-Caching in einem DAB-Cache-Medium zwischengepuffert werden, da der Ablageort der Datei, d.h. der Volume-Set, dynamisch geändert werden kann.

- Datenbank-Pubsets

  Bei reinen Datenbank-Pubsets kann es zur Verbesserung der „zeitlichen Lokalität“ besser sein, eine kleinere Segmentgröße zu wählen: z.B. 8 KB statt dem Standardwert 32 KB (`/START-DAB-CACHING`, Parameter `CACHE-SEGMENT-SIZE`).

In der Praxis führen die verkürzten Ein-/Ausgabezeiten i.d.R. zu einer deutlichen Durchsatzerhöhung und damit zu Verschiebungen der Last und der CPU-Auslastung.

Hinweis zu DAB für SX100 (Verwendung der internen Platten für BS2000-Daten): Die für SX-Server maximal empfohlene Anzahl DVS-Ein-/Ausgaben (siehe Abschnitt „Richtwerte für die BS2000/OSD-Server“ auf Seite 353) bezieht sich auf Konfigurationen mit (externen) Plattenspeichersystemen. Die Leistung interner Platten liegt deutlich darunter. In SX100-Konfigurationen, deren BS2000-Produktivdaten ausschließlich auf internen Platten liegen, wird der Einsatz von DAB empfohlen, da mit DAB als Lese-Cache Engpässe bei der Ein-/Ausgabe in vielen Fällen vermieden werden können. Bei einem typischen Hauptspeicherausbau wird bei SX100-D1 und -D2 für DAB ein Lese-Cache von 500 MB empfohlen,
bei SX100-D3 1.000 MB.
Zu berücksichtigen ist auch der Systemparameter `JTABSMEM` (siehe Seite 371).
Für SX100-D1 und -D2 wird für `JTABSMEM` ein Wert von 500 MB empfohlen, für SX100-D3 1.500 MB.

Bei Anwendungen, die eine höhere Write-IO-Rate verursachen, sollten zur Steigerung des Durchsatzes zusätzliche Platten verwendet werden.
(Der Einsatz von DAB für Write-IOs wird nicht generell empfohlen.)

Ausführliche Informationen zum Einsatz des DAB sind im Handbuch „DAB“ [6] zu finden.

7.3.3 User-PFA-Caching

Beim User-PFA-Caching (PFA: Performant File Access) entscheidet die Systembetreuung, welche Pubsets einen Cache-Bereich zugeordnet bekommen, welche Eigenschaften dieser Cache-Bereich hat und welche Anwender vom Caching dieser Pubsets profitieren sollen.
Eine ausführliche Beschreibung ist im Handbuch „Einführung in die Systembetreuung“ [11] zu finden.

PFA aus der Sicht des Anwenders

Abhängig von der Definition des Cache-Bereichs kann die Nutzung eines PFA-Caches für einen Pubset entweder global für alle Dateien oder gezielt für spezielle Dateien erfolgen:

- Ist der Cache-Bereich mit der Eigenschaft `CACHED-FILES=*BY-SYSTEM` (d.h. AutoDAB ist im Einsatz) oder `CACHED-FILES=*ALL` (alle Anwender-Dateien des Pubsets unterliegen dem Caching) definiert, so muss der Anwender keine weiteren Aktionen durchführen, um vom Caching auf diesem Pubset zu profitieren.
- Ist der Cache-Bereich mit `CACHED-FILES=*BY-USER-SELECTED` definiert, so wirkt das Caching wie anschließend beschrieben, nur für entsprechend attributierte Dateien.

Mit `/CREATE-FILE`, `/MODIFY-FILE-ATTRIBUTES`, `/ADD-FILE-LINK` bzw. den Makros `FILE` und `CATAL` können folgende Dateieigenschaften vergeben werden:

Operand	Erläuterung
`PERFORMANCE`	bestimmt das Caching-Verhalten (Hauptspeicher/Globalspeicher):
`= *STD`	kein Caching
`= *HIGH`	Caching mit Verdrängung nach LRU
`= *VERY-HIGH`	Caching ohne Verdrängung
`= *USER-MAX`	höchstes Performance-Attribut, zu dem der Anwender berechtigt ist
`USAGE`	die erhöhten Performance-Anforderungen gelten:
`= *READ-WRITE`	für Lese- und Schreiboperationen
`= *READ`	nur für Leseoperationen
`= *WRITE`	nur für Schreiboperationen
`DISK-WRITE`	Datenkonsistenz wird hergestellt:
`= *IMMEDIATE`	nach jeder Schreiboperation (Voraussetzung: nichtflüchtiges Cache-Medium!)
`= *BY-CLOSE`	erst nach CLOSE-Verarbeitung
`= *STD`	für permanente Dateien gilt `*IMMEDIATE`, für temporäre Dateien gilt `*BY-CLOSE`

Werden im Rahmen einer Folgeverarbeitung (i.d.R. bei Batch-Betrieb) mehrmals die gleichen Dateien geöffnet bzw. geschlossen, so kann der Anwender den Durchsatz weiter verbessern, indem er beim Schließen der Datei

- die Invalidierung der Lesedaten im Cache verhindert bzw.
- das Sichern der im Cache befindlichen Schreibdaten unterbindet (bei flüchtigem Speichermedium nur für temporäre Dateien zu empfehlen).

Zusätzlich wirkt sich günstig aus, dass wiedereröffnete Dateien nicht erneut in den Cache eingelagert werden müssen.
Ermöglicht wird diese Variante des PFA-Cachings (HIPERBATCH = High Performance Batch Processing) über `/ADD-FILE-LINK`, Operand `CLOSE-MODE= *KEEP-DATA-IN-CACHE`, bzw. den Makro `CLOSE`, Operand `KEEP-DATA-IN-CACHE`.

PFA aus der Sicht der Systembetreuung

Damit die Performance-Anforderungen des Anwenders wirksam werden können, müssen entsprechende Berechtigungen in den Benutzerkatalog eingetragen werden (`/ADD-USER`, `/MODIFY-USER-ATTRIBUTES` bzw. `/MODIFY-USER-PUBSET-ATTRIBUTES`):

Operand	**Erläuterung**
`DMS-TUNING-RESOURCES`	vereinbart Performance-Maßnahmen
`= *NONE`	Caching nicht zugelassen
`= *CONCURRENT-USE`	für Anforderung `PERFORMANCE=*HIGH`
`= *EXCLUSIVE-USE`	für Anforderung `PERFORMANCE=*VERY-HIGH`
`PERM-/TEMP-/WORK-SPACE-LIMIT = *PARAMETERS(...)`	Speicherplatz-Kontingente der Anwender festlegen (jeweils für permanente, temporäre und Arbeitsdateien):
`HIGH-PERF-SPACE= ...`	für hochperformanten Speicherplatz
`VERY-HIGH-PERF-SPACE= ...`	für sehr hochperformanten Speicherplatz

Es ist darauf zu achten, dass Berechtigung und Speicherplatz-Kontingente im Benutzerkatalog desjenigen Pubsets eingetragen werden, auf dem die Datei liegt.

Mit den folgenden Kommandos steuert die Systembetreuung den Einsatz von PFA-Caching:

Kommando	**Funktion**
MODIFY-PUBSET-CACHE-ATTRIBUTES	Cache-Bereichseigenschaften im MRSCAT eines Pubsets oder Volume-Sets festlegen
IMPORT-/EXPORT-PUBSET	bewirkt implizit die Einrichtung bzw. Auflösung eines im MRSCAT beschriebenen Cache-Bereichs
START-/STOP-PUBSET-CACHING	dynamische Einrichtung bzw. Auflösung eines im MRSCAT beschriebenen Cache-Bereichs während einer Pubset-Session
SHOW-CACHE-CONFIGURATION	PFA-Cache-Bereichs-Konfiguration ausgeben
SHOW-PUBSET-PARAMETER	Cache-Bereichs-Beschreibung im statischen und dynamischen MRSCAT ausgeben
FORCE-DESTROY-CACHE	Auflösung eines PFA-Cache-Bereichs erzwingen
MODIFY-PUBSET-DEFINITION-FILE	(logische) Performance-Eigenschaften eines Volume-Sets eines SM-Pubsets festlegen
MODIFY-PUBSET-PROCESSING	bewirkt implizit die Einrichtung bzw. Auflösung von Cache-Bereichen bei der aktiven Hinzunahme bzw. Entfernung von Volume-Sets zu bzw. aus einem SM-Pubset

Die Definition des Cache-Mediums zum entsprechenden Pubset erfolgt über die Operanden von /MODIFY-PUBSET-CACHE-ATTRIBUTES:

Operand	**Erläuterung**
CACHE-MEDIUM	bestimmt das Cache-Medium:
=*MAIN-MEMORY	Hauptspeicher
=*GLOBAL-STORAGE	Globalspeicher
CACHE-SIZE=n	Größe des Cache-Bereichs
FORCE-OUT	legt fest, ab welchem Cache-Füllungsgrad beschriebene Inhalte auf Platte gesichert werden:
=*AT-HIGH-FILLING	75%
=*AT-LOW-FILLING	25%
=*NO	keine periodische Sicherung

Bezüglich des Operanden CACHE-MEDIUM sind noch folgende Angaben wichtig:

Operand	Erläuterung
CACHE-SEGMENT-SIZE =*4KB/*8KB/*16KB/ *32KB	Größe eines Cache-Segments, d.h. minimale Größe des Datenbereichs, der bei einem Read-Miss eingelagert wird: 4, 8, 16 oder 32 KB (nur für nicht-automatische Cache-Bereiche relevant)
CACHED-FILES =*BY-USER-SELECTED =*ALL =*BY-SYSTEM	bestimmt, welche Dateien den Cache nutzen sollen: über Performance-Attribute bestimmt der Anwender, welche seiner Dateien den Cache nutzen sollen alle Anwender-Dateien nutzen den Cache automatischer Cache-Bereich: durch das automatisierte, intelligente Caching des AutoDAB werden die performance-relevanten Dateien automatisch ermittelt; Für die ausgewählten Dateien wird der zu ihrem Zugriffsprofil passende Prefetch-Faktor eingestellt, die Dateien werden zyklisch überwacht, um eine optimale Cache-Performance zu gewährleisten.

Der Einsatz von User-PFA-Caching ist erforderlich, wenn bei einem Shared-Pubset ein lokales Write-Caching für jeden Server unterstützt werden soll (bei ADM-PFA-Caching ist nur Read-Caching möglich).

7.3.4 Platten-Emulation (GS-Volumes) im Globalspeicher

GS-Volumes sind emulierte Platten variabler Kapazität, deren Daten nur auf dem Globalspeicher (GS) liegen. Für den Nutzer sehen sie weitgehend wie normale Platten aus, mit der Einschränkung, dass sie nicht für den Home-Pubset oder für Paging-Pubsets verwendet werden können.

Die Systembetreuung kann mit den Kommandoschnittstellen der Subsysteme GSVOL und GSMAN emulierte Platten im Globalspeicher einrichten bzw. abbauen. Diese GS-Volumes müssen nicht wie andere Platten explizit generiert werden, sondern sind automatisch innerhalb eines bestimmten mnemotechnischen Bereichs vorgeneriert.
In einem „Parallel HIPLEX-Verbund“ können die GS-Volumes auch als Shared-Pubsets eingesetzt werden. Das NK4-Format liefert den schnellsten Zugriff auf den Globalspeicher.

GS-Volumes bieten (neben GS-Caching mit DAB) die höchste Ein-/Ausgabe-Performance im BS2000, wobei Anwendungen auf GS-Volumes von dieser hohen Perfomance generell profitieren, ohne dass Randbedingungen wie gute Lokalität der Anwendungszugriffe (hohe Hit-Rate) erfüllt sein müssen.

Folgende Kommandos stehen der Systembetreuung zur Verwaltung von GS-Volumes zur Verfügung:

Kommando	**Funktion**
`CREATE-GS-VOLUME`	GS-Volume mit vorgegebener Mnemonic und vorgegebenem Format in einer bereits angelegten GS-Partition anlegen
`SHOW-GS-VOLUME-ATTRIBUTES`	Informationen über alle verfügbaren GS-Volumes ausgeben
`DELETE-GS-VOLUME`	über die Geräte-Mnemonic bezeichnetes GS-Volume auflösen

Zum Einrichten eines GS-Volumes muss zunächst eine GS-Partition (im Mono- oder Dual-Modus) in der benötigten Größe angelegt werden. Danach kann mit `/CREATE-GS-VOLUME` ein GS-Volume eingerichtet und danach mit `/ATTACH-DEVICE` zugeschaltet werden.

7.4 Transaktionsbetrieb und BCAM

Dieser Abschnitt beschreibt Maßnahmen zur Antwortzeitoptimierung im Transaktionsbetrieb und bei BCAM.

Die Netzqualität hat in vielen Fällen den größten Einfluss auf das Antwortzeitverhalten. Paketverluste, Paketverfälschungen und Reihenfolgevertauschungen zwingen das Transportsystem zu Fehlerbehandlungen, die zu Paketwiederholungen und einer verminderten Sendeleistung führen. Eine Netzanalyse muss neben den Endsystemen alle anderen Netzkomponenten, wie Switches, Router, Firewalls, Gateways usw. einbeziehen. Die Messkomponenten von BS2000/OSD lassen sich durch SNMP-Agenten in eine solche Infrastruktur integrieren.

7.4.1 Phasen einer OLTP-Transaktion

Die performance-relevanten Phasen einer OLTP-Transaktion (siehe Abschnitt „Online-Anwendung“ auf Seite 18) sind:

1. Netzlaufzeit bis zum Server
2. Warten auf die Annahme der Transaktion durch BCAM
3. Bearbeitung durch BCAM und Weiterleitung an die TP-Anwendung (z.B. openUTM)
4. Warten auf Annahme durch openUTM
5. Bearbeitungszeit der Transaktion, gesteuert durch openUTM mit folgenden Detailphasen:
   a) CPU-Bedarf durch die Anwendung / durch openUTM
   (mit Warten auf CPU-Zuteilung)
   b) Ein-/Ausgabe-Bearbeitung in der Anwendung / in openUTM
   (mit Warten auf das Ende der Ein-/Ausgabe)
   c) Warten auf Auftragsannahme durch Datenbank-Tasks
   d) CPU-Bedarf durch Datenbank-Aktivitäten
   (mit Warten auf CPU-Zuteilung)
   e) Bearbeitung der Ein-/Ausgabe in der Datenbank-Task

   Diese Detailphasen können mehrfach auftreten
6. Senden der Antwort an BCAM
7. Warten auf die Annahme der Antwort durch BCAM
8. Bearbeitung durch BCAM

9. Übergabe der Ausgabedaten für den Netztransfer
10. Netzlaufzeit bis zum Client

Nur die Phasen 3 - 9 können mit BS2000-Mitteln (im Wesentlichen mit openSM2, siehe Handbuch „openSM2“ [19]) messtechnisch erfasst werden.

Für die Phase 2 liefert BCAM einen Indikator über mögliche zeitliche Verzögerungen. openSM2 stellt im Messprogramm BCAM-Connection die von BCAM erfassten Zeiten grafisch dar:

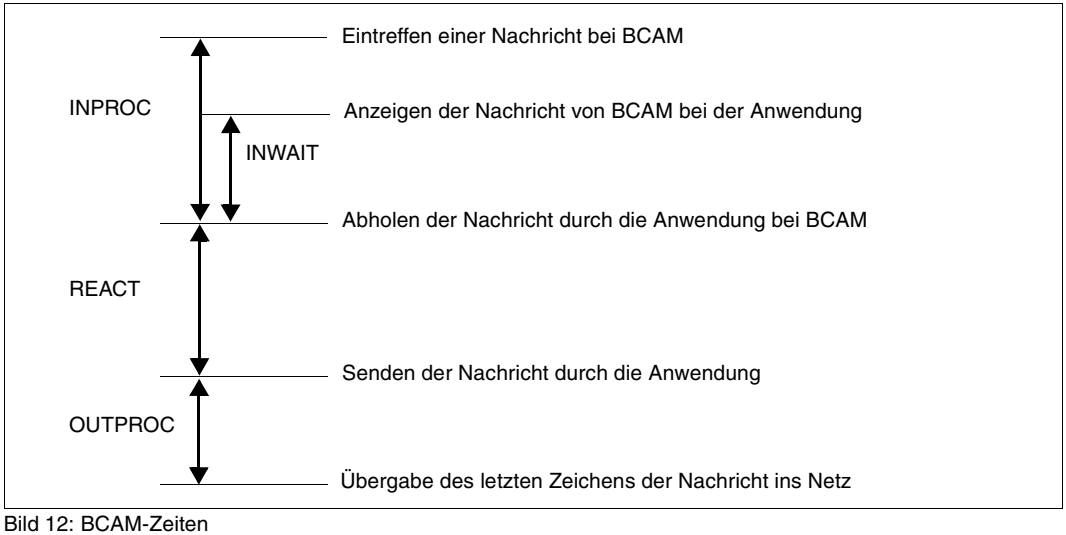
Eintreffen einer Nachricht bei BCAM
INPROC
Anzeigen der Nachricht von BCAM bei der Anwendung
INWAIT
Abholen der Nachricht durch die Anwendung bei BCAM
REACT
Senden der Nachricht durch die Anwendung
OUTPROC
Übergabe des letzten Zeichens der Nachricht ins Netz

Bild 12: BCAM-Zeiten

Folgende Zeiten entsprechen sich:

INPROC	Phasen 3 und 4
INWAIT	Phase 4
REACT	Phasen 5 - 7
OUTPROC	Phasen 8 und 9

7.4.2 Optimierung der einzelnen Phasen

Dieser Abschnitt behandelt Engpässe im openUTM- und BCAM-Umfeld, die zu Antwortzeitverlängerungen in den einzelnen Phasen führen können. Er zeigt auf, wie diese Engpässe messtechnisch erkannt und auf welche Art sie behoben bzw. gemildert werden können.

Phasen 1 und 10: Netzlaufzeiten

Allgemeine Hinweise zum LAN-Anschluss finden Sie im Abschnitt „LAN-Anschluss“ auf Seite 94.

Phase 2: Warten bis zur Annahme der eingehenden Nachricht durch BCAM (Inbound Flow Control):

Steuerungsmechanismen zur Kontrolle des Datenflusses schützen das Transportsystem vor Datenüberflutung durch die Partner. Dadurch wird verbindungsspezifisch ein (schneller) Sender an die Verarbeitungsgeschwindigkeit eines (langsamen) Empfängers angepasst.

BCAM schützt so seinen Speicherpool, der allen Anwendungen und Verbindungen zur Verfügung steht. In Phasen, in denen der BCAM-Pool stark ausgelastet ist, hindert BCAM seine Partner daran, Nachrichten ins BS2000-System zu senden. Dadurch kann es zu steigenden Antwortzeiten kommen.

Ursache für eine länger oder dauerhaft anhaltende hohe Auslastung des BCAM-Pools können Anwendungen sein, die ihre Nachrichten langsam abholen. Auch eine, für die zu erbringende Verarbeitungsleistung, zu geringe Poolgröße kann zu einer hohen Auslastung des BCAM-Pools führen.

openSM2 stellt Messdaten für die Analyse der Auslastung des BCAM-Pools zur Verfügung, siehe Messprogramm `RESPONSETIME` im Handbuch „openSM2“ [19].

BCAM selbst erlaubt es mit dem Kommando `/BCMON` und durch Analyse der Werte der Konsolmeldung `BCA0B21` zu ermitteln, ob ein Engpass im BCAM-Puffer vorliegt.

Kurzbeschreibung der Vorgehensweise:

- Ermittlung der eingestellten Maximalwerte (optional) mit
  `/SHOW-BCAM-PARAMETERS PARAMETER=*LIMITS`
- Einschalten des BCAM-Monitoring (Ausgabe der Messwerte alle <n> Sekunden):
  `/BCMON MODE=ON,RECORD=RES-MEM,SEC=<n>`
- Beschreibung der wichtigsten Ausgabe-Werte der Konsolmeldung `BCA0B21`:

  `USED-BCAM-MIN-I` minimale BCAM-Pufferbelegung für eingehende Nachrichten in KB

  `LIMIT-ACT` aktuelle obere Grenze für die Pufferbelegung in KB

- Indikator für eine hohe Auslastung des BCAM-Puffers durch eingehende Nachrichten:
  `(USED-BCAM-MIN-I) * 4 > LIMIT-ACT`
- Alternativ oder ergänzend zu den obigen Punkten kann mit: `/BCSET THRESHOLD-MSG=ON` eine Warnmeldung angefordert werden.

  Dann wird die Konsolmeldung `BCAB021` ausgegeben, wenn BCAM wegen Pool-Engpass die eingehenden Nachrichten länger als 5 Sekunden bremst (oder keine Sendeanforderungen der Anwendung annehmen kann, siehe Phase 7).
  Diese Warnmeldung wird mit `/BCSET THRESHOLD-MSG=OFF` wieder ausgeschaltet.
- Optimierungsmaßnahme bei einem Engpass im BCAM-Pool:
  Mit dem Kommando `/BCMOD RESMEM=<n>` sollte der maximal zulässige Schwellwert deutlich erhöht werden (ideal wäre: `<n>=3*LIMIT-ACT`).

Phasen 3 und 8: Bearbeitung der Ein- bzw. Ausgangs-Nachricht in BCAM

Die Zeitwerte für diese Phasen sollten im niedrigen einstelligen Bereich (in Millisekunden) liegen.

Phase 4: Warten auf openUTM

Die Zeit, die zwischen der Auftragserteilung an openUTM und der Annahme des Auftrags verstreicht, wird als INWAIT-Zeit bezeichnet. Sie wird pro Anwendung ermittelt und ist in der INPROC-Zeit enthalten.

openSM2 erfasst die INWAIT-Zeiten (wie auch die INPROC- , REACT- und OUTPROC-Zeiten) in 5 Zeitintervallen, den so genannten Buckets. Buckets können nur global, nicht aber anwendungsspezifisch eingestellt werden. Zur Vereinfachung der Überwachung sollten Intervall-Einteilung so vorgenommen werden, dass alle nicht akzeptablen Zeiten in das letzte Intervall fallen (Overrun-Wert).

Beispiel

Die normale Antwortzeit beträgt 100 - 200 ms (typisch für große S-Server). Es sollen kurzfristige Schwankungen bis zum Faktor 2 toleriert werden. Eine länger andauernde Verdopplung der Antwortzeit soll aber nicht toleriert werden.

Die Buckets in openSM2 sollten demnach so eingestellt werden, dass im Overrun-Intervall alle INWAIT-Zeiten gezählt werden, die 400 ms oder größer sind, z.B. mit:
`SET-BCAM-CONNECTION-PARAMETER INWAIT-BUCKETS=(50,100,200,400)`

Mit dieser Anweisung werden die Buckets so eingestellt, dass im ersten Intervall alle Wartezeiten < 50 ms, im zweiten Intervall alle Wartezeiten zwischen 50 und 100 ms, im dritten Intervall alle Wartezeiten zwischen 100 und 200 ms, im vierten Intervall alle Wartezeiten zwischen 200 und 400 ms und im Overrun-Intervall alle Wartezeiten > 400 ms gezählt werden.

Mit den Komponenten INSPECTOR oder ANALYZER von openSM2 müssen nun (für jede Anwendung) die Messwerte des Overrun-Intervalls überwacht werden. Die Werte werden in Prozent (bezogen auf die im Messintervall erfassten Zeitwerte) dieser Applikation ausgegeben. Ab einem Prozentwert von 10 oder höher deutet dies auf Engpässe bei der Auftragsannahme durch die UTM-Tasks hin.

Messmöglichkeit in openUTM

Mit dem UTM-Kommando `KDCINF STAT` werden mehrere nützliche UTM-Messwerte ausgegeben, siehe openUTM-Handbuch „Anwendungen administrieren“ [21]. Für die Analyse, ob die Zahl der UTM-Tasks einen Engpass darstellen könnte, liefert der Ausgabewert `%Load` einen wichtigen Hinweis. Dieser gibt die mittlere Auslastung aller UTM-Tasks des letzten Messintervalls an. Ein zumindest kurzzeitiger Engpass deutet sich an, wenn der Wert größer als 90 (%) wird.

Schwellwertüberwachung der UTM-Taskanzahl mit openSM2

Ein sich anbahnender Engpass an UTM-Tasks lässt sich mit dem Messreport `UTM-Applikation` von openSM2 erkennen. Dazu müssen von diesem Report die Werte für die Dauer einer Transaktion in Sekunden (`DT`), die Anzahl der Transaktionen pro Sekunde (`TX`) und die Anzahl der UTM-Tasks für die Applikation (`UT`) ermittelt werden.

Damit kann die mittlere Auslastung der UTM-Tasks einer Anwendung errechnet werden: `Load (in %) = 100 * DT * TX / UT`.

Im INSPECTOR von openSM2 kann dieser errechneten Wert einer Schwellwertüberwachung unterworfen werden. Bei Überschreitung eines Wertes von 90 (%) kann z.B. eine entsprechende E-Mail an die Systembetreuung erzeugt werden.

Optimierungsmaßnahme

Mit dem UTM-Kommando `KDCAPPL TASKS=<n>` kann die Anzahl der UTM-Tasks applikationsspezifisch und schrittweise solange erhöht werden, bis die INWAIT-Zeiten in einem akzeptablen Bereich liegen. Die so gefundene optimale Taskanzahl sollte in der Startparameter-Datei von openUTM eingetragen werden. Sie wirkt dann ab dem nächsten Anwendungsstart. Übersteigt `<n>` den im KDCDEF-Lauf festgelegten maximalen Wert, so muss dieser Maximal-Wert erhöht und ein neuer KDCDEF-Lauf gestartet werden.

Anmerkung

Nur wenn deutlich mehr UTM-Tasks als nötig gestartet werden, kann dies zu geringen Leistungseinbußen durch die etwas höhere Hauptspeicher- und CPU-Nutzung führen.

Phase 5 und 6: Bearbeitung der Transaktion

Die in dieser Phase (und in der Phase 7) anfallende Zeit wird im BCAM-Connection-Report als REACT-Zeit ausgewiesen.

Tuning der IO-Performance beim Zugriff auf die KDCFILE

Neben den in diesem Handbuch beschriebenen Maßnahmen bei der Hardware und in BS2000/OSD kann die Performance von Anwendungen mit hohen Transaktionsraten auch in openUTM durch optimierte Schreibzugriffe auf die KDCFILE verbessert werden. Dazu können in openUTM die Pagepools und/oder der Wiederanlaufbereich aus der KDCFILE ausgelagert werden. Diese ausgelagerten Bereiche werden nun selbst wieder auf mehrere Volumes verteilt.

Beispiel:

Der Pagepool soll auf 2 Public-Volumes,
der Wiederanlaufbereich auf 4 Public-Volumes verteilt werden:

```
/CREATE-FILE FILE-NAME=<filebase>.P01A, -
SUPPORT=*PUBLIC-DISK(VOLUME=<v1>,SPACE=*RELATIVE(PRIMARY-ALLOCATION=666))

/CREATE-FILE FILE-NAME=<filebase>.P02A, -
SUPPORT=*PUBLIC-DISK(VOLUME=<v2>,SPACE=*RELATIVE(PRIMARY-ALLOCATION=666))

/CREATE-FILE FILE-NAME=<filebase>.R01A, -
SUPPORT=*PUBLIC-DISK(VOLUME=<v3>,SPACE=*RELATIVE(PRIMARY-ALLOCATION=300))

/CREATE-FILE FILE-NAME=<filebase>.R02A, -
SUPPORT=*PUBLIC-DISK(VOLUME=<v4>,SPACE=*RELATIVE(PRIMARY-ALLOCATION=300))

/CREATE-FILE FILE-NAME=<filebase>.R03A, -
SUPPORT=*PUBLIC-DISK(VOLUME=<v5>,SPACE=*RELATIVE(PRIMARY-ALLOCATION=300))

/CREATE-FILE    FILE-NAME=<filebase>.R04A, -
SUPPORT=*PUBLIC-DISK(VOLUME=<v6>,SPACE=*RELATIVE(PRIMARY-ALLOCATION=300))
```

Außerdem müssen in der KDCDEF die folgenden Parameter in der MAX-Anweisung geändert werden: `PGPOOLSFS=2`, `RECBUFFS=4`.
Im KDCDEF-Lauf werden dann die oben definierten Dateien verwendet, wobei das KDCDEF-Programm eventuell die Werte für `PRIMARY-` und `SECONDARY-ALLOCATION` modifiziert. Ohne obige Kommandos würde KDCDEF die Dateien selbst anlegen (ohne Volume-Zuweisung).

Nach dem Neustart von openUTM werden die neuen Dateien verwendet.

Steuerung der UTM-Aufträge durch TAC-Klassen

Ähnlich der Kategoriesteuerung mit PCS (siehe Abschnitt „Einführung in das PCS-Konzept“ auf Seite 243) können Transaktionen in openUTM in so genannte „TAC-Klassen“ aufgeteilt werden. Diese TAC-Klassen können mit zwei nicht kombinierbaren Methoden gesteuert werden:

- Prioritätensteuerung
- Prozessbeschränkung

Details zur Auftragssteuerung in openUTM finden Sie im openUTM-Handbuch „Anwendungen generieren“ [22].

Einsatzempfehlung:

- Bei der Aufteilung der TACs in TAC-Klassen muss darauf geachtet werden, dass höherpriore TAC-Klassen nicht durch TACs aus nieder-prioren TAC-Klassen gebremst werden (Verwendung von blockierenden Aufrufen).
- Es wird empfohlen, nicht mehr als 3 oder 4 TAC-Klassen zu definieren.
- Die Prioritätensteuerung dient vor allem dazu, dass bei (kurzfristigen) Überlasten lang laufende TACs aus nieder-prioren TAC-Klassen kurz laufende TACs aus höher-prioren TAC-Klassen nicht behindern. Somit werden hoch-priore Transaktionen unter Ausnutzung aller gestarteten Prozesse bevorzugt.
- Die Prozessbeschränkung dient dazu, dass lang laufende TACs andere, kurz laufende TACs nicht behindern können. Der Vorteil dieser Variante liegt darin, dass hier immer dafür gesorgt werden kann, dass genügend freie UTM-Tasks für neue (und wichtige) TACs zur Verfügung stehen.
- Zusätzlich können TACs durch Angabe der `RUNPRIO` in der TAC-Anweisung gesteuert werden. Dies ist aber nur für höchst-priore TACs zu empfehlen und ist mit dem Prioritätengefüge aller in BS2000/OSD ablaufenden Tasks abzustimmen.

Weitere Performance-Hinweise zu openUTM:

- Überwachung der Cache Hit-Rate

  Mit dem UTM-Kommando `KDCINF STAT` (siehe Seite 212) sollte (zumindest gelegentlich) überprüft werden, ob die Trefferquote im Pagepool des UTM-Caches ausreichend hoch ist. Bei Werten unter 90 (%) sollte der UTM-Cache eventuell vergrößert werden (siehe openUTM-Handbuch „Anwendungen generieren“ [22]).

- Einsatz von UTM-F

  Diese UTM-Variante ist hauptsächlich für Anwendungen mit „retrieval“-Zugriffen und keinen bis sehr wenigen Updates geeignet. Sie dient zur Vermeidung von Ein-/Ausgaben bei reduzierter Funktionalität (hinsichtlich Ausfallsicherheit und Wiederanlauf).

Phase 7: Warten vor BCAM

Diese Phase ist im BCAM-Connection-Report ein Teil der REACT-Zeit (siehe Phase 5).

Analog zu Phase 2 kann BCAM den Steuerungsmechanismen des Partners zur Kontrolle des Datenflusses unterliegen. Dies ist erkennbar durch ZWR-Werte > 0 (ZWR=Zero Window Receive) im openSM2-Report BCAM. BCAM nimmt zwar in solchen Situationen eine gewisse zu versendende Datenmenge der Anwendung an, wird jedoch bei Überschreiten eines Grenzwertes die Annahme von weiteren Daten verweigern.

BCAM verzögert die Annahme von Daten auch in Phasen, in denen der BCAM-Pool stark ausgelastet ist. Ursache für eine länger oder dauerhaft anhaltende hohe Auslastung des BCAM-Pools können Verbindungen sein, die der Kontrolle des Datenflusses unterliegen. Auch eine, für die zu erbringende Verarbeitungsleistung, zu geringe Poolgröße kann zu einer hohen Auslastung des BCAM-Pools führen.

Analog zu Phase 2 bietet BCAM eine Überwachungsmöglichkeit.
Zeigt die Meldung `BCA0B21` hohe Werte für `USED-BCAM-MIN-O` an, so sollte wie in Phase 2 der BCAM-Pool vergrößert werden.

Phase 8 und 9: Verzögerung bei der Übergabe ins Netz

Die Zeit in Phase 8 (reine BCAM-Verarbeitung) liegt im einstelligen Millisekunden-Bereich. Die Zeiten für Phase 8 und 9 sind gemeinsam in der OUTPROC-Zeit enthalten. Eine Überwachung der OUTPROC-Zeit analog zur INPROC-Zeit wird empfohlen (siehe Seite 211). Hohe Werte im Overrun-Intervall deuten auf mögliche Probleme der Netzperformance hin (z.B. durch Fehlfunktionen in Routern oder Switches).

8 Systemsteuerung

8.1 Job-Management

Das Job-Management (JMS) bietet eine Vielzahl von Steuermöglichkeiten für die Auswahl auf Verarbeitung wartender Aufträge (Jobs).

Zur Charakterisierung bestimmter Eigenschaften von Aufträgen dienen die Job-Klassen. Neben Parametern für die Auswahl von Aufträgen enthalten sie auch wesentliche Anweisungen für die anschließende Verarbeitung. Mit diesen Verarbeitungs-Parametern können auch andere Anwendungen, wie TP- oder Dialog-Anwendungen, hinsichtlich ihrer Ausführung gesteuert werden. Die Angabe einer Job-Klasse ist also nicht nur für die Batch-Verarbeitung wichtig.

Vom Anwender gewünschte Auswahl-Strategien für Aufträge (Job-Scheduling-Strategien) werden durch Job-Streams realisiert.

8.1.1 Job-Klassen

Der Parameter `JOB-TYPE=*BATCH` einer Job-Klasse legt fest, dass diese Klasse dem Job-Scheduling unterworfen wird. Aufträge einer Job-Klasse, für die `JOB-TYPE=*DIALOG` gilt, werden sofort gestartet, sofern der Parameter `CLASS-LIMIT` dies erlaubt.

Auswahlparameter für Batch-Aufträge

`CLASS-WEIGHT`

kennzeichnet die Dringlichkeit der in einer Job-Klasse wartenden Aufträge gegenüber einer anderen Klasse (nur wichtig nach System-Sättigungszuständen).

Wertebereich `<integer 1..9>`; 1 ist die niedrigste, 9 die höchste Dringlichkeit.

`JOB-PRIORITY`

legt die Wichtigkeit der wartenden Aufträge innerhalb einer Job-Klasse fest.

Wertebereich `<integer 1..9>`; 1 ist die höchste, 9 die niedrigste Wichtigkeit.

CPU-LIMIT

bestimmt die CPU-Zeit, die ein Auftrag in dieser Job-Klasse verbrauchen darf.
Der Parameter NO-CPU-LIMIT=*YES bewirkt das gleiche wie der Eintrag PRIVILEGE=*NO-CPU-LIMIT im Benutzerkatalog.

START

gibt die möglichen Startattribute an (*SOON, *WITHIN,...).
Die Zusatzbedingung ALLOWED=*IMMEDIATE hat die gleiche Wirkung wie der Eintrag PRIVILEGE=*START-IMMEDIATE im Benutzerkatalog. Sie bedeutet, dass ein Auftrag sofort gestartet werden darf, auch wenn das Job-Klassen-Limit bereits erreicht ist.

Wird in einem XCS-Verbund bei /ENTER-JOB bzw. /ENTER-PROCEDURE der Operand HOST=*ANY angegeben, so erfolgt die Verteilung der Aufträge auf die einzelnen Rechner des Verbunds automatisch (Details siehe Handbuch „HIPLEX MSCF“ [13]).

Für die Auswahl des Zielrechners werden die Kriterien in folgender Reihenfolge berücksichtigt:

1. Status der Job-Klasse

   Die gewünschte Job-Klasse muss definiert und aktiv sein (sie darf z.B. nicht durch /HOLD-JOB-CLASS angehalten sein).

2. Kein Vorliegen eines System-Sättigungszustandes

3. Belegung der Job-Klasse

   Solange das Job-Klassen-Limit (CLASS-LIMIT) nicht erreicht ist, wird für Aufträge die sofort ausgeführt werden sollen, die Differenz zwischen Job-Klassen-Optimum (CLASS-OPTIMUM) und der Anzahl bereits gestarteter Aufträge berücksichtigt.

   Ist das Job-Klassen-Limit ausgeschöpft oder überschritten, wird die Differenz zwischen dem Job-Klassen-Limit und der Anzahl akzeptierter (d.h. bereits gestarteter und wartender) Aufträge herangezogen.

Ausführungsparameter für Batch-Aufträge, TP- und Dialoganwendungen

Damit Anwendungen in der gewünschten Kategorie unter Berücksichtigung des entsprechenden Task-Attributs TP, DIALOG oder BATCH (siehe auch Abschnitt „Task-Management“ auf Seite 223) sowie der gewünschten Prioritäten ausgeführt werden, sind folgende Parameter zu beachten:

`TP-ALLOWED = *NO / *YES(CATEGORY=name)`

`DIALOG-ALLOWED = *NO / *YES(CATEGORY=name)`

`BATCH-ALLOWED= *NO / *YES(CATEGORY=name)`

Diese Parameter legen das Task-Attribut für die Job-Klasse fest. Damit werden spezielle systeminterne Ablaufparameter, optimiert jeweils für die Betriebsarten TP, Dialog oder Batch, zugewiesen.

Ist kein Kategoriename angegeben, wird der zugehörige Standard-Kategoriename angenommen (z.B. bei `TP-ALLOWED=*YES` der Standard-Kategoriename TP).

Ein Kategoriename darf nicht mehreren Task-Attributen zugeordnet werden.

`START-ATTRIBUTE = *BATCH / *DIALOG / *TP`

bestimmt, mit welchem Task-Attribut Tasks dieser Job-Klasse gestartet werden.
Die Parameterwerte von `START-ATTRIBUTE` und `TP-`, `DIALOG-` und `BATCH-ALLOWED` müssen zusammenpassen.

`RUN-PRIORITY`

legt die Ausführungspriorität (= Task-Priorität) fest.

Mit dem Parameter `RUN-PRIORITY=*PARAMETERS(DEFAULT=n, MAXIMUM=n)` kann die maximale Task-Priorität, die sich ein Anwender geben darf, vorgegeben werden.

Beispiel

Eine wichtige Produktionsanwendung (Auftragsabwicklung) soll als TP-Anwendung mit hoher Priorität in einer eigenen Kategorie gefahren werden.

Mit dem Dienstprogramm JMU (siehe Handbuch „Dienstprogramme“ [7]) wird eine Job-Klasse definiert (`//DEFINE-JOB-CLASS`), das Zugriffsrecht festgelegt (`//GRANT-JOB-CLASS-ACCESS`) und die Ablage in der Datei `SJMSFILE` vorgenommen.

```
NAME=P,           (wie Produktion)
JOB-TYPE=*BATCH,
CLASS-LIMIT=5,
CLASS-WEIGHT=2,
JOB-PRIORITY=*PARAMETERS(DEFAULT=3),
NO-CPU-LIMIT=*YES,
START=*PARAMETERS(DEFAULT=*SOON),
TP-ALLOWED=*YES(CATEGORY=AUFTRAG),
START-ATTRIBUTE=*TP,
RUN-PRIORITY=*PARAMETERS(DEFAULT=150,MAXIMUM=128)
```

Mit `//SET-MODIFICATION-MODE` wird festgelegt, ob das Dienstprogramm JMU die Änderung direkt im laufenden System ausführt und/oder in der Datei SJMSFILE, die erst beim nächsten Systemstart ausgewertet wird.
Für den Start der Produktionsanwendung genügt bei `/ENTER-JOB` die Angabe `JOB-CLASS=P`.

Anmerkung

Aus Kompatibilitätsgründen besteht eine logische ODER-Verknüpfung zwischen den Einträgen der Job-Klasse und der Benutzerkennung, wobei die jeweils „größeren“ Rechte gelten.

Beispiel

Job-Klasse	**Benutzerkatalog**	**Status**
`TP-ALLOWED=*NO`	`MAX-ALLOWED-CATEGORY=TP`	TP erlaubt

`RUN-PRIORITY=`
`  *PARAMETERS(DEFAULT=150,`
`  MAXIMUM=128)`
	`MAXIMUM-RUN-PRIORITY=180`	maximale Priorität=128

8.1.2 Job-Streams

Definiert die Systembetreuung keine Job-Klassen, so werden alle Aufträge der Klasse $SYSJC zugeordnet (auf die der Anwender keinen Zugriff hat) und vom fest mit dem System gekoppelten **System-Job-Scheduler $SYSJS** verwaltet.

Der System-Job-Scheduler ist eine System-Task (siehe Abschnitt „Erzeugen und Beenden von Tasks“ auf Seite 263) und läuft privilegiert im Funktionszustand TPR. Seine auf dem LIFO-Prinzip (Last in first out) beruhende Auswahlstrategie ist nicht beeinflussbar.

Unabhängig von definierten Job-Klassen und eventuell realisierten Auswahlstrategien lässt der System-Job-Scheduler während des gesamten Systemlaufs das Starten von Aufträgen unter der Kennung TSOS zu.

Definierte Job-Klassen mit dem Parameter `JOB-TYPE=*BATCH` werden einem Job-Stream (auch Job-Scheduler genannt) zugeordnet (`STREAM=name`). Eine Job-Klasse kann nur **einem** Job-Stream angehören, aber ein Job-Stream kann mehrere Job-Klassen verwalten.

Die Bearbeitung der Jobs im Stream (Sortieren nach vorgegebener Auswahlstrategie) übernimmt der **Standard-Job-Scheduler**. Der Standard-Job-Scheduler ist ein Anwenderprogramm und läuft im Funktionszustand TU unter der Kennung TSOS. Die Auswahlstrategie wird durch den Stream-Parameter (`STREAM-PARAMETER`) bestimmt. Er wird durch das Dienstprogramm JMU (`//DEFINE-JOB-STREAM`) eingestellt.

Um verschiedene Auswahlstrategien zu realisieren, können die bei der Stream-Definition festgelegten Scheduling-Parameter dynamisch geändert werden (`//MODIFY-JOB-STREAM` des Dienstprogramms JMU).

Bis zu 16 Job-Streams können maximal gleichzeitig installiert sein.

Auswahl-Strategien (STREAM-PARAMETER='...')

- Auswahl nach Ankunftszeit

  ```
  JOB-PRIORITY=NO,CPU-TIME=NO,WAIT-TIME=NO
  ```

  `WAIT-TIME` ist die Wartezeit des Auftrags nach Annahme.
  Diese Strategie empfiehlt sich, wenn die CPU-Zeitanforderungen der Aufträge in etwa gleich sind.

- Auswahl nach Priorität

  ```
  JOB-PRIORITY=YES,CPU-TIME=NO,WAIT-TIME=NO
  ```

  Gewährleistet die Bevorzugung wichtiger Jobs.

- Auswahl nach CPU-Zeitbedarf

  ```
  JOB-PRIORITY=NO,CPU-TIME=YES,WAIT-TIME=NO
  ```

  Jobs mit geringeren CPU-Zeitanforderungen werden vorgezogen.

- Auswahl nach Priorität und CPU-Zeitbedarf

  `JOB-PRIORITY=YES,CPU-TIME=YES,WAIT-TIME=NO`

  Bei Aufträgen mit gleicher Job-Scheduling-Priorität entscheidet der geringere CPU-Zeitbedarf. Bei gleichem CPU-Zeitbedarf ist die höhere Priorität maßgebend.

- Auswahl nach Priorität und Wartezeit

  `JOB-PRIORITY=YES,CPU-TIME=NO,WAIT-TIME=YES`

  Durch Einbeziehung der Wartezeit nach der Job-Annahme haben auch niederpriore Aufträge die Chance, ausgewählt zu werden.

- Auswahl nach Durchsatz

  `JOB-PRIORITY=NO,CPU-TIME=YES,WAIT-TIME=YES`

  Bevorzugung von Aufträgen mit geringem CPU-Zeitbedarf unter Einbeziehung der Wartezeit nach der Annahme.

- Auswahl nach Durchsatz und Priorität

  `JOB-PRIORITY=YES,CPU-TIME=YES,WAIT-TIME=YES`

  Zusätzlich zur Auswahl nach Durchsatz wird die Job-Scheduling-Priorität berücksichtigt.

Der Job-Scheduler übergibt die von ihm ausgewählten und sortierten Jobs an den **Klassen-Scheduler**.

Der Klassen-Scheduler ist keine eigene Task, sondern gehört zum Kern des Job-Managements. Er sorgt für die Einhaltung des von der Systembetreuung gewünschten Job-Mixes (über die `CLASS-LIMIT`-Parameter der einzelnen Job-Klassen).

Bei der Auflösung von Stau-Situationen nach einer Systemsättigung (Sättigung des Seitenwechselbereichs) bestimmt der Parameter `CLASS-WEIGHT` die Dringlichkeit der einzelnen Job-Klassen.

8.2 Task-Management

In BS2000/OSD werden logisch zusammengehörende Anforderungen an das System und deren Ausführung als Task verwaltet.

Wenn es sich bei diesen Anforderungen an das System um UTM-Anwendungen handelt, dann können die unterschiedlichen Transaktionscodes innerhalb von UTM mit Hilfe so genannter TAC-Klassen gesteuert werden. Dabei stehen ähnliche Mittel zur Verfügung, wie sie für Tasks bzw. Kategorien unter PRIOR bzw. PCS eingesetzt werden.
Eine Zusammenfassung dazu befindet sich auf Seite 214.
Detaillierte Informationen finden Sie in den in den Handbüchern von openUTM.

8.2.1 Einführung in das PRIOR-Konzept

Unter dem Namen PRIOR sind jene Routinen des Task-Managements zu verstehen, die es ermöglichen:

- Tasks mit Hilfe von Kategorien und Prioritäten zu steuern
- die Serverauslastung durch interne Mechanismen zu überwachen und zu steuern

Konkret bedeutet dies:

- die Verwaltung der Betriebsmittel Hauptspeicher und CPU samt Durchführung entsprechender Kontrollfunktionen
  (siehe Abschnitt „Verwalten der Betriebsmittel Hauptspeicher und CPU“ ab Seite 265)
- die Steuerung der Tasks über Warteschlangen
  (siehe Abschnitt „Steuern der Tasks über Warteschlangen“ ab Seite 282)

Das Konzept beruht auf einer Prioritäten-Steuerung ohne Einflussnahme auf die Größe der Betriebsmittelzuteilung. Das bedeutet, dass der Systembetreuung nur Einfluss darüber eingeräumt wird, welcher von mehreren Bewerbern ein Betriebsmittel zuerst erhält. Er hat nur geringen Einfluss darauf, welchen Anteil an der Leistung eines Betriebsmittels ein Bewerber in einer gewissen Zeitspanne erhält.

8.2.1.1 Task-Kategorien

Zur Verbesserung der individuellen Steuerungsmöglichkeiten – je nach den Anwendererfordernissen – erfolgt die Einteilung der Tasks in Kategorien. Es gibt 16 Kategorien.

Vier davon sind immer existent mit den Standard-Kategorienamen:

SYS	nur für System-Tasks
TP	Transaktions-Tasks
DIALOG	Dialog-Tasks
BATCH	Batch-Tasks

Weitere Kategorien können von der Systembetreuung unter einem frei wählbaren Namen eingerichtet werden.
Jede Task ist einer Kategorie zugeordnet.

Zusätzlich gibt es vier Task-Attribute, deren Namen identisch sind mit den Standard-Kategorienamen SYS, TP, DIALOG und BATCH. Den Task-Attributen sind spezielle, für das Task-Scheduling wichtige Ablaufparameter zugeordnet.

Das Task-Attribut TP zeichnet sich gegenüber den anderen Task-Attributen durch eine speziell auf die Bedürfnisse des Transaktionsbetriebs optimierte Hauptspeicher-Verwaltung aus (wenige, hinsichtlich Working-Set-Bedarf meist größere User-Tasks hängen funktional zusammen und bedienen viele Terminals).
Das Task-Attribut TP kann erlangt werden durch Definition in der Job-Klasse oder durch Aufruf des TINF-Makros (in diesem Fall muss die dazu erforderliche Berechtigung im Benutzerkatalog eingetragen sein).

Wesentliches Kennzeichen einer Kategorie ist der Multiprogramming-Level (MPL). Darunter ist diejenige Anzahl Tasks pro Kategorie zu verstehen, die das Recht zur Hauptspeicher-Nutzung besitzen, sich also im aktiven Zustand befinden.

Mit den Kategorie-Attributen

- MIN MPL
- MAX MPL
- WEIGHT

spezifiziert die Systembetreuung (`/MODIFY-TASK-CATEGORIES`) die Wichtigkeit der Kategorien untereinander für die Aktivierung (= Zuteilung der Berechtigung zur Hauptspeicher-Nutzung).

Ob es zu einer Aktivierung kommt oder ob eine Task-Verdrängung durchgeführt wird, hängt außer von den Kategorie-Attributen von der Serverauslastung und der Priorität der betroffenen Task ab (siehe Abschnitt „Verwalten der Betriebsmittel Hauptspeicher und CPU“ auf Seite 265).

Die Vorgabe von **MIN MPL** garantiert eine gewisse Mindestunterstützung einer Kategorie. Das System versucht vorrangig, den spezifizierten MIN MPL-Wert zu erreichen.

Die Vorgabe von **MAX MPL** bedeutet keine feste Grenze, d.h. es wird über den maximalen MPL-Wert hinaus aktiviert, solange kein Betriebsmittelengpass vorliegt.

Durch den Parameter **WEIGHT** wird die Aktivierungs- bzw. Deaktivierungs-Reihenfolge gesteuert. Zusätzlich beeinflusst der Parameter schwach die Vergabe der CPU.

Kategoriewechsel

Die Systembetreuung kann mit /MOVE-TASK-TO-CATEGORY die Zuordnung einer Task zu einer Kategorie ändern, wenn etwa eine andere (bessere) Bedienung dieser Task oder auch eine Entlastung einer Kategorie erreicht werden soll (mit oder ohne Einsatz von PCS).

Auswirkungen der Kategoriesteuerung

Aufgrund der genannten Eigenschaften hat die Kategoriesteuerung im Unterlast- bzw. Normallast-Bereich keinen nennenswerten steuernden Einfluss.

Im **Voll-Last-Bereich** bzw. **Überlast-Bereich** (also bei Betriebsmittelengpässen) hat die Kategorie-Steuerung eine starke Wirkung und dient daher zur **Lastbegrenzung**. Weniger wichtige Kategorien werden in den Hintergrund gedrängt.
Dieser Voll-Last-Bereich wird bei Servern mit sehr großem Hauptspeicher nur noch in Ausnahmefällen erreicht. Die Überlastung der CPU reicht alleine nicht aus, um die Lastbegrenzung wirksam werden zu lassen. Daher ist bei diesen Servern die Kategoriesteuerung weitgehend wirkungslos.

8.2.1.2 Task-Prioritäten

Durch die Vergabe der Priorität kennzeichnet der Anwender die Dringlichkeit seiner Anforderungen hinsichtlich der Ausführung. Es gibt 3 Klassen von Prioritäten:

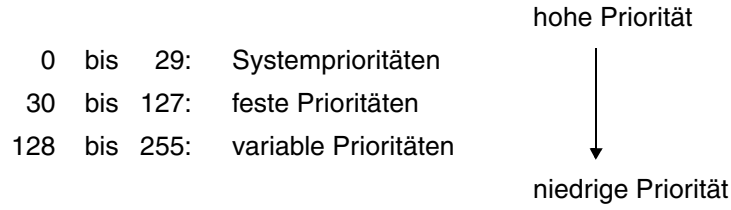

Für den Anwender stehen die variablen und die festen Prioritäten zur Verfügung. Sie werden in dieser Form als externe Prioritäten bezeichnet.

Die Prioritätsvergabe ist möglich:

- vom Anwender auf Kommandoebene bei `/SET-LOGON-PARAMETERS`
  `/ENTER-JOB`
  `/CHANGE-TASK-PRIORITY`
- vom Anwender auf Programmebene mit dem Makroaufruf TINF
- vom Systemverwalter bzw. Operator als Standardwert
  in der Job-Klasse (`RUN-PRIORITY`) und mit `/CHANGE-TASK-PRIORITY`

Die maximal erlaubte Priorität muss in der Job-Klasse bzw. im Benutzerkatalog eingetragen sein.

Variable Prioritäten

Charakteristisch für variable Prioritäten ist die dynamische Einstellung der internen Priorität mit dem HRN-Algorithmus (Highest Response ratio Next), basierend auf dem Verhältnis

$$\frac{\text{Verweilzeit (Elapsed Time)}}{\text{Verbrauchte CPU-Zeit}}$$

unter Berücksichtigung einer „Startpriorität“. Diese Startpriorität ergibt sich aus der vergebenen externen Priorität, den Kategorie-Gewichten, dem Leistungsvermögen des Servers und der derzeitigen Belastung.

Dies gewährleistet eine angemessene Bedienung auch für Tasks mit niedriger Startpriorität.

Die variable Priorität wird zu folgenden Zeitpunkten berechnet bzw. verbessert:

- bei der Aktivierung (siehe Abschnitt „Hauptspeicher-Verwaltung“ auf Seite 267)
- bei Micro-Time-Slice-Runout (siehe Abschnitt „CPU-Verwaltung“, Punkt: Kontrollfunktionen, Seite 281)

- periodisch (jede Sekunde)

Die periodische Überprüfung wird für alle aktiven Tasks sowie für alle ablaufbereiten, inaktiven Tasks durchgeführt (die also auf die Zuteilung der Berechtigung zur Hauptspeicher-Nutzung warten, sich im Zustand „inactive ready“ befinden).

Feste Prioritäten

Bei festen Prioritäten bleibt die vorgegebene externe Priorität unverändert. Sie wird starr in die interne Priorität umgerechnet.

Auswirkungen der Priorität

Da die Priorität sowohl bei der Aktivierung als auch bei der Initiierung berücksichtigt wird, zeigt die Vergabe einer von der „normalen“ externen Priorität 255 abweichende, also bessere Startpriorität bei allen Lastsituationen (bei Unter-, Voll- oder Überlast) ähnliche Auswirkungen.

Bei der Einreihung einer Ein-/Ausgabe-Anforderung in die Warteschlange vor dem Gerät wird die Priorität nicht berücksichtigt.
Die Priorität wirkt daher umso stärker, je CPU-intensiver eine Task und deren Konkurrenten sind.

Empfehlungen und Richtwerte

PRIOR steuert die Zuteilung der Betriebsmittel Hauptspeicher und CPU an User- und System-Tasks entsprechend der vorgegebenen Kategorie- und Prioritätsparameter.

Dabei spielen die Prioritäten eine besonders wichtige Rolle, da man mit ihnen einzelne Tasks bevorzugen kann, während mit der Kategoriesteuerung nur Kategorien als Ganzes priorisiert werden können. Besonders bei TP-Anwendungen sollten die zentralen Tasks in der Priorität angehoben werden. Der Einsatz von festen Prioritäten ist sehr vorsichtig zu handhaben. Sie unterliegen nicht dem HRN-Algorithmus und können daher den Server monopolisieren. Es sollten keinesfalls bessere Prioritäten als 80-100 vergeben werden.

Anmerkung

Die Parameter für die **Kategorie SYS** können nicht verändert werden und sind auf folgende Werte eingestellt:

```
MIN MPL  = 30
MAX MPL  = 64
WEIGHT   = 512
```

System-Tasks haben folgende Prioritäten:

Permanent vorhandene System-Tasks:		22	
Ausnahmen:	TSN VMM:	16	
	TSN PGE:	1	
	TSN RMM:	128	beim Startup
		50	nach SYSTEM READY
Dynamisch erzeugte Tasks (z.B. DIAA, DSSM):		60	
Ausnahmen (z.B. BCAM):		30	

Grundsätzlich ist zu beachten, dass man eine Betriebsmittelknappheit auch durch geschickte Einstellungen nicht beseitigen kann. Während mit viel Erfahrung bei einem CPU-Engpass oder bei knappem Hauptspeicher wenigstens noch für besonders wichtige Tasks zu Lasten anderer eine Erleichterung geschaffen werden kann, ist dies bei Engpässen in der Peripherie nur schlecht möglich.

In den folgenden Abschnitten wird davon ausgegangen, dass Überlegungen hinsichtlich aufgabengerechter Dimensionierung bereits im Rahmen der Kapazitätsplanung erfolgt sind. Das Hauptaugenmerk wird auf die optimale Nutzung der installierten Betriebsmittel gelegt.

8.2.1.3 Lastanalyse

Um aus der Vielfalt der Parameter-Einstellmöglichkeiten von PRIOR die günstigste Einstellung auswählen zu können, ist die genaue Kenntnis der Last erforderlich. Folgende Fragen müssen im Rahmen der Lastanalyse beantwortet werden:

- Welche Leistungsanforderungen bestehen für welche Anwendung?
- Welche Anwendung kann im Überlastfall zugunsten wichtigerer Anwendungen in den Hintergrund gedrängt werden?
- Welche Anwendung gehört in welche Kategorie?

Zunächst ist es notwendig, das Steuerungs-Ziel zu definieren:

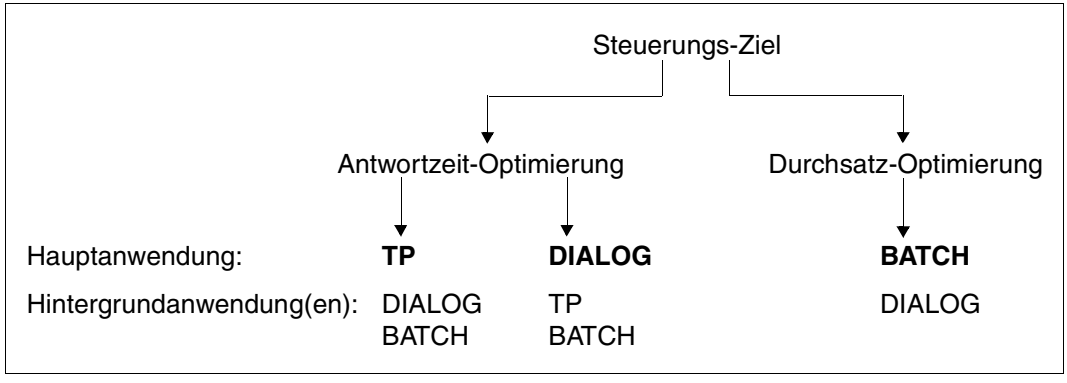

Die Unterscheidung in Antwortzeit- bzw. Durchsatz-Optimierung ist wichtig, weil hier gegenläufige Tendenzen vorliegen: Gutes Antwortzeitverhalten setzt kurze Wartezeiten vor den Betriebsmitteln (speziell vor Kanälen, Steuerungen und Plattanlaufwerken) voraus; daher darf deren Auslastung nicht zu hoch sein.

Die weitere Unterscheidung im Rahmen der Antwortzeit-Optimierung, ob der Schwerpunkt bei TP- oder Dialog-Anwendungen liegt, ist für die Einstellung der Kategorieparameter von Bedeutung.

- Dialog-Anwendungen stellen eine härtere Hauptspeicher-Beanspruchung hinsichtlich der Paging-Intensität dar als TP-Anwendungen (siehe auch Abschnitt „Untersuchen eines systemorientierten Leistungsproblems“ auf Seite 311).
- TP-Anwendungen reagieren andererseits empfindlicher auf Hintergrundlasten, besonders auf Paging. Diese Empfindlichkeit ist umso größer, je weniger Tasks die Abwicklung der Anwendung bewerkstelligen. Die TP-Anwendung ist als Hauptanwendung anzusehen, wenn die Anzahl der TP-Transaktionen ≥ 50 % der Gesamtanzahl an Transaktionen beträgt.

Die Anzahl Transaktionen pro Sekunde für die TP- und Dialog-Anwendung kann entweder nach den Formeln im Abschnitt „Formulieren einer Leistungserwartung“ auf Seite 22 oder durch eine Messung mit dem Software-Monitor SM2 ermittelt werden.

Beispiel: Transaktionsrate

```
600 TP-Terminalbenutzer:
    Durchschnittliche Denkzeit       20 s (inklusive Netzlaufzeit)
    Durchschnittliche Antwortzeit     1 s

 50 Dialog-Tasks:
    Durchschnittliche Denkzeit       20 s (inklusive Netzlaufzeit)
    Durchschnittliche Antwortzeit     2 s
```

Transaktionsrate für die TP-Anwendung: $\frac{600}{1 + 20} = 28{,}6\ \text{Trans/s}$

Transaktionsrate für die Dialog-Anwendung: $\frac{50}{2 \quad 20} = 2{,}3\ \text{Trans/s}$

Man sollte in jedem Fall eine Vermessung mit dem Software-Monitor SM2 durchführen (speziell bei komplexeren Anwendungen). Es empfiehlt sich die **Vermessung von Teillasten**.

Zweckmäßigerweise beginnt man mit dem wichtigsten Teil der Last, setzt die PRIOR-Parameter für die Hauptanwendung entsprechend den Empfehlungen (siehe „Einstellen der Kategorieparameter“ auf Seite 232 und „Prioritätenvergabe“ auf Seite 240) und ermittelt das Antwortzeitverhalten, die Transaktionsrate und die Betriebsmittelauslastung. Diese Werte werden für die Optimierung der Hauptanwendung im Mischlastbetrieb benötigt, um beurteilen zu können, wie stark die Hauptanwendung durch die Nebenanwendungen beeinträchtigt wird.

Durch diese Vermessung der Hauptanwendung können die in der Kapazitätsplanung getroffenen Annahmen verifiziert bzw. der tatsächliche Betriebsmittelbedarf aufgezeigt werden. Tritt bereits beim alleinigen Betrieb der Hauptanwendung ein unbefriedigendes Leistungsverhalten auf, so ist eine Engpass-Analyse durchzuführen (siehe Abschnitt „Durchführung einer Engpass-Analyse“ auf Seite 303).

Im Anschluss daran stellt man die PRIOR-Parameter für die Hintergrundanwendung entsprechend den Empfehlungen ein (siehe „Einstellen der Kategorieparameter“ auf Seite 232 und „Prioritätenvergabe“ auf Seite 240) und erhöht stufenweise die Last.

Beispiel: Antwortzeit-Optimierung

Bevorzugung der TP-Anwendung vor der Dialog- und Batch-Anwendung

1. Schritt:

   Messen der reinen TP-Anwendung (modifizierte PRIOR-Parameter)

   Messzeit je nach Lastfall: 15 Minuten bei kaum schwankender Last

   60 Minuten bei stark schwankender Last

   Ermitteln von Antwortzeitverhalten, Transaktionsrate, Betriebsmittelauslastung

2. Schritt:

   Dazuschalten der Dialog-Anwendung (modifizierte PRIOR-Parameter)
   Messzeit: 60 Minuten

3. Schritt:

   Dazuschalten der Batch-Anwendung (modifizierte PRIOR-Parameter)
   Messzeit: mehrere Messungen, jeweils 60 Minuten

   Beobachten des Laufzeitverhaltens

Die Hauptanwendung wird durch die Nebenanwendung eine gewisse Bremsung erfahren (ca. 10 - 20%). Das ist unvermeidbar. Durch geschickte Wahl und Begrenzung der Nebenanwendungen erreicht man, dass diese Bremsung erträglich bleibt. Die Nebenanwendungen sollten möglichst nur solche Betriebsmittel belasten, die von der Hauptanwendung kaum benötigt werden. Zusätzlich ist eine hohe Empfindlichkeit der Nebenanwendungen bezüglich MPLs und Prioritäten vorteilhaft.

Anwenderrechte

Nach der Lastanalyse ist es notwendig, über `/MODIFY-USER-ATTRIBUTES` bzw. die `JOB-CLASS`-Parameter die „endgültigen“ Anwenderrechte (welche Priorität der Anwender höchstens vergeben darf) festzulegen.

Auch ist zu überprüfen, ob für DCAM-, UTM-, UDS-, SESAM-Anwendungen die TP-Berechtigung eingetragen ist, damit die Vorteile des Task-Attributs TP zur Geltung kommen können.

8.2.1.4 Einstellen der Kategorieparameter

Vorrangiges Ziel ist für Server mit knappem Speicher die effiziente Aufteilung des **verfügbaren** seitenwechselbaren Hauptspeichers NPP (Number of Pageable Pages) entsprechend der angegebenen Wichtigkeit der Kategorien.

Knapper Speicher liegt vor, wenn es bei vernünftig eingestellten MPL-Werten INACTIVE READY TASKS gibt (Report „Active and inactive tasks for category“ in der Reportgruppe CATEGORY-QUEUE von SM2).
Wird dieser Zustand im Betrieb nie erreicht, dann kann der Leser diesen Abschnitt überspringen und zum Abschnitt „Prioritätenvergabe“ auf Seite 240 gehen.

Damit PRIOR auf kleinere Lastschwankungen variabel reagieren kann, sollte der Working-Set-Bedarf der Tasks, der sich aus der Summe der MIN MPL-Werte aller Kategorien ergibt, `(0,3 bis 0,5) * NPP` sein. Die Wahl des Faktors (0,3 oder 0,5) hängt davon ab, wo der Schwerpunkt der Anwendung liegt (siehe unten).

Richtwerte für den durchschnittlichen Working-Set-Bedarf (4-KB-Seiten):

TP-Tasks:	WS_{TP}	=	200	bis	400	Seiten für UTM- und DCAM-Tasks
		=	500	bis	1.000	Seiten für DB-Tasks
Dialog-Tasks:	WS_{DIAL}	=	50	bis	150	Seiten
Batch-Tasks:	WS_{BATCH}	=	50	bis	200	Seiten

Die Verwaltung des Working-Sets für Systemroutinen und Common-Memory-Pools, die von Anwenderprogrammen aufgerufen werden, erfolgt global in der Kategorie SYS (Platzhalter ist die TSN=PGE).

Kategorie SYS: WS_{SYS} = 2.000 bis 4.000 Seiten

Der NPP-Wert ist dem dem ACTIVITY-Report von SM2 zu entnehmen.

Bei den folgenden Überlegungen wird der Einfachheit halber angenommen, dass aus Anwendersicht nur die Kategorien mit den Standard-Kategorienamen TP, DIALOG und BATCH vorhanden sind.

a) Hauptanwendung: TP

Hintergrundanwendungen: Dialog
Batch

Kategorie TP

In dieser Kategorie befinden sich die Tasks mit den höchsten Leistungsansprüchen. Auch im Überlastfall ist eine Lastbegrenzung dieser Kategorie nicht erwünscht. Daher muss der Wert für MAX MPL gleich der Gesamtanzahl der im System vorhandenen TP-Tasks sein (inklusive der Verwaltlungstasks, z.B. TDADM, Datenbankadministrator, ...).

Der Wert für MIN MPL sollte der gewünschten Anzahl aktiver TP-Tasks entsprechen. Dies wird i.d.R. nahe oder gleich dem MAX MPL-Wert sein. Ein zu kleiner Wert für MIN MPL führt bei Überlast zu unerwünschter Zwangsdeaktivierung (siehe Abschnitt „Hauptspeicher-Verwaltung“ auf Seite 267) von TP-Tasks.

Empfohlene Werte:

$$\begin{aligned} \text{MIN MPL}_{TP} &= 0{,}8 \text{ MAX MPL}_{TP} \\ \text{MAX MPL}_{TP} &= \text{Gesamtanzahl vorhandener TP-Tasks} \\ \text{WEIGHT} &= 500 \end{aligned}$$

Kategorie DIALOG

Diese Kategorie ist meist durch stärkere Lastschwankungen gekennzeichnet. PRIOR versucht, den von der Systembetreuung vorgegebenen MIN MPL-Wert notfalls durch Verdrängungen von Tasks anderer Kategorien zu erreichen (siehe Abschnitt „Hauptspeicher-Verwaltung“ auf Seite 267).

Da hier die Dialog-Anwendung im Hintergrund laufen soll, darf der Wert für MIN MPL nicht zu hoch sein.

Durch den Einfluss der Denkzeit sind nicht alle Dialog-Tasks gleichzeitig aktiv. Die Anzahl der aktiven Dialog-Tasks kann mit folgender Formel abgeschätzt werden:

$$\text{Anzahl aktive DIALOG-Tasks} = \frac{\text{Gesamtzahl DIALOG-Tasks}}{N}$$

$$\text{wobei } N = \frac{\text{durchschnittliche Denkzeit} + \text{Antwortzeit}}{\text{durchschnittliche Antwortzeit}}$$

Richtwerte: durchschnittliche Denkzeit (inklusive Netzlaufzeit) = 16 s
durchschnittliche Antwortzeit = 4 s

$$N = \frac{20\ s}{4\ s} = 5$$

Für die Ermittlung des MIN MPL-Wertes ist maßgebend, wieviel seitenwechselbarer Hauptspeicher (gemäß der Formel `0,5 * NPP` bei Schwerpunkt TP-Betrieb) nach Abzug des Working-Set-Bedarfs der Hauptanwendung, der Kategorie SYS bzw. evtl. erforderlicher Batch-Tasks für **aktive** Dialog-Tasks verfügbar ist (siehe Beispiel). Der Wert für MAX MPL ist als Lastbegrenzung für vorübergehend auftretende Überlastsituationen gedacht. Er sollte auf den doppelten Wert von MIN MPL eingestellt werden.

Empfohlene Werte:

$$\text{MIN MPL}_{DIAL} = \frac{0{,}5 \bullet \text{NPP} - (\text{MIN MPL}_{TP} \bullet \text{WS}_{TP} + \text{MIN MPL}_{BATCH} \bullet \text{WS}_{BATCH} + \text{WS}_{SYS})}{\text{WS}_{DIAL}}$$

WS_{TP}: durchschnittlicher Working-Set-Bedarf pro TP-Task

WS_{DIAL}: durchschnittlicher Working-Set-Bedarf pro Dialog-Task

WS_{BATCH}: durchschnittlicher Working-Set-Bedarf pro Batch-Task

WS_{SYS}: durchschnittlicher Working-Set-Bedarf für Systemroutinen und Common-Memory-Pools

Anmerkung

Die Berücksichtigung des Batch-Anteils ist an dieser Stelle nur dann erforderlich, wenn für die entsprechende IT-Installation aus betrieblichen Gründen eine Mindestanzahl parallell laufender Batch-Tasks zwingend notwendig ist.

```
MAX MPL  = 2 MIN MPL
WEIGHT   = 100     (50 < WT < 200)
```

Kategorie BATCH

Im Normalfall werden Batch-Tasks als Hintergrundlast eingesetzt, um die freien Betriebsmittel zu nutzen. In diesem Fall errechnet sich der Wert für MIN MPL aus der Größe des seitenwechselbaren Hauptspeichers (genauer: 0,5 • NPP), abzüglich des Working-Set-Bedarfs für die Hauptanwendung TP, die Dialog-Anwendung und die Kategorie SYS.

Der Wert für MAX MPL richtet sich nach der Serverauslastung und sollte vom MIN MPL-Wert nicht allzuweit auseinanderliegen.

Empfohlene Werte:

$$\text{MIN MPL}_{BATCH} = \frac{0{,}5 \bullet \text{NPP} - (\text{MIN MPL}_{TP} \bullet \text{WS}_{TP} + \text{MIN MPL}_{DIAL} \bullet \text{WS}_{DIAL} + \text{WS}_{SYS})}{\text{WS}_{BATCH}}$$

$$\text{MAX MPL}_{BATCH} = \text{MIN MPL}_{BATCH} + 1$$

```
WEIGHT       = 10     (1 < WT < 50)
```

Beispiel zu Hauptanwendung TP

MM = 64 MB

Hauptanwendung TP: 6 UTM-Tasks, 2 DB-Tasks
insgesamt: 10 TP-Tasks

Hintergrundanwendung: 10 Dialog-Tasks
2 Batch-Tasks (im Minimum)

Kategorie TP:

MIN MPL_{TP} = 8
MAX MPL_{TP} = 10
WEIGHT = 500

Kategorie DIALOG:

Anzahl aktiver Dialog-Tasks = $\frac{\text{Gesamtzahl DIALOG-Tasks}}{N} = \frac{10}{5} = 2$

MIN MPL_{DIAL} = 2
MAX MPL_{DIAL} = 4
WEIGHT = 100

Kategorie BATCH:

MIN MPL_{BATCH} = 2
MAX MPL_{BATCH} = 3
WEIGHT = 10

64 MB = 16000 Seiten, residenter MM-Bedarf = 1500 Seiten
→ NPP = 14500 Seiten.

$$\text{MIN } MPL_{TP} \bullet WS_{TP} + \text{MIN } MPL_{DIAL} \bullet WS_{DIAL} + \text{MIN } MPL_{BATCH} \bullet WS_{BATCH} + WS_{SYS} \leq 0{,}5 \bullet NPP$$

$$(6 \bullet 300 + 2 \bullet 800) + 2 \bullet 150 + 2 \bullet 100 + 2000 = 1800 + 1600 + 300 + 200 + 2000 =$$

$$6100 \leq 0{,}5 \bullet 14500 = 7250$$

b) Hauptanwendung: Dialog

Hintergrundanwendungen: TP
Batch

Kategorie TP

Dass die TP-Anwendung als Hintergrundanwendung erscheint, bedeutet nicht zwangsläufig, dass nur geringe oder gar keine Leistungsansprüche gestellt werden, sondern dass die Anzahl der TP-Transaktionen < 50% der Anzahl der Gesamttransaktionen ist.
Dieser Fall tritt immer dann auf, wenn TP-Anwendungen neu eingeführt werden und erst eine relativ kleine Anzahl Terminalbenutzer das neue Verfahren benutzt.
Da **eine** TP-Task immer mehrere Terminalbenutzer bedient bzw. diese normalerweise auch einen wesentlich größeren Working-Set-Bedarf gegenüber Dialog-Tasks hat, ist es grundsätzlich nicht wünschenswert, dass TP-Tasks im Überlastfall zwangsdeaktiviert werden.
Es sollte daher auch hier der Wert für MAX MPL gleich der Gesamtanzahl der im System vorhandenen TP-Tasks sein.
Ebenso sollte der Wert für MIN MPL nahe oder gleich dem MAX MPL-Wert gewählt werden.

Empfohlene Werte:

```
MIN MPL_TP2  = 0,8 MAX MPL_TP
MAX MPL_TP2  = Gesamtanzahl vorhandener TP-Tasks
WEIGHT       = 500
```

Kategorie DIALOG

Liegt der Schwerpunkt der Anwendung auf der Dialog-Seite, so bedeutet das eine höhere Beanspruchung des Hauptspeichers hinsichtlich Paging-Intensität (siehe auch Abschnitt „Untersuchen eines systemorientierten Leistungsproblems“ auf Seite 311) als bei TP-Anwendungen.

Der Working-Set-Bedarf der Tasks, der sich aus der Summe der MIN MPL-Werte der Kategorien TP, DIALOG, BATCH ergibt, sollte daher ≤ `0,3 * NPP` sein.

Für die Ermittlung des MIN MPL-Wertes ist wesentlich, wieviel seitenwechselbarer Hauptspeicher (gemäß der Formel `0,3 * NPP` bei Schwerpunkt Dialogbetrieb) nach Abzug des Working-Set-Bedarfs der TP-Tasks, der Kategorie SYS bzw. notwendiger Batch-Tasks für aktive Dialog-Tasks verfügbar ist (siehe Beispiel).

Auch hier ist für die Zahl der aktiven Dialog-Tasks in erster Näherung einzusetzen:

$$\frac{\text{Gesamtzahl Dialog-Tasks}}{5}$$

Empfohlene Werte:

$$\text{MIN MPL}_{\text{DIAL}} = \frac{0{,}3 \bullet \text{NPP} - (\text{MIN MPL}_{\text{TP}} \bullet \text{WS}_{\text{TP}} + \text{MIN MPL}_{\text{BATCH}} \bullet \text{WS}_{\text{BATCH}} + \text{WS}_{\text{SYS}})}{\text{WS}_{\text{DIAL}}}$$

Anmerkung

Der Batch-Anteil ist an dieser Stelle nur dann zu berücksichtigen, wenn aus betrieblichen Gründen eine gewisse Mindestanzahl parallel laufender Batch-Tasks erforderlich ist.

$$\text{MAX MPL}_{\text{DIAL}} = 2 \bullet \text{MIN MPL}_{\text{DIAL}}$$

$$\text{WEIGHT} = 300 - 500$$

Kategorie BATCH

Für den Fall, dass Batch-Tasks als reine Hintergrundlast eingesetzt werden, gelten folgende Werte:

$$\text{MIN MPL}_{\text{BATCH}} = \frac{0{,}3 \bullet \text{NPP} - (\text{MIN MPL}_{\text{TP}} \bullet \text{WS}_{\text{TP}} + \text{MIN MPL}_{\text{DIAL}} \bullet \text{WS}_{\text{DIAL}} + \text{WS}_{\text{SYS}})}{\text{WS}_{\text{BATCH}}}$$

$$\text{MAX MPL}_{\text{BATCH}} = \text{MIN MPL}_{\text{BATCH}} + 1$$

$$\text{WEIGHT} = 10 \quad (1 < \text{WT} < 50)$$

Beispiel zu Hauptanwendung Dialog

MM = 64 MB

Hauptanwendung Dialog: 45 Dialog-Tasks

Batch: 2 Batch-Tasks (im Minimum)

Hintergrundanwendung: 2 UTM-Tasks, 1 DB-Task
insgesamt: 4 TP-Tasks

Kategorie TP:

MIN MPL_{TP} = 3
MAX MPL_{TP} = 4
WEIGHT = 500

Kategorie DIALOG:

Anzahl aktiver Dialog-Tasks = $\frac{\text{Gesamtzahl Dialog-Tasks}}{N} = \frac{45}{5} = 9$

MIN MPL_{DIAL} = 9
MAX MPL_{DIAL} = 18
WEIGHT = 400

Kategorie BATCH:

MIN MPL_{BATCH} = 2
MAX MPL_{BATCH} = 3
WEIGHT = 10

64 MB = 16000 Seiten, residenter MM-Bedarf = 1500 Seiten
→ NPP = 14000 Seiten.

$$MIN\ MPL_{TP} \bullet WS_{TP} + MIN\ MPL_{DIAL} \bullet WS_{DIAL} + MIN\ MPL_{BATCH} \bullet WS_{BATCH} + WS_{SYS} \leq 0{,}3 \bullet NPP$$

$$2 \bullet 200 + 1 \bullet 500) + 9 \bullet 100 + 2 \bullet 100 + 2000 = 400 + 500 + 900 + 200 + 2000 =$$

$$4000 \leq 0{,}3 \bullet 14500 = 7250$$

c) Hauptanwendung: Batch

Hintergrundanwendung: Dialog

Diese Belastung ist typisch für den Nachtschichtbetrieb von Servern, deren Hauptspeicher für den Tages-Online-Betrieb ausgelegt ist.
Batch-Anwendungen stellen i.d.R. eine weitaus geringere Hauptspeicher-Beanspruchung bezüglich der Paging-Intensität dar als Online-Anwendungen, belasten aber wesentlich mehr die CPU.
Die Anzahl der verkraftbaren Batch-Tasks hängt daher weniger von der Hauptspeicher-Größe als von der CPU-Geschwindigkeit ab.
Die Einstellung der Kategorieparameter hat in diesem Fall keine Bedeutung (eine gewünschte Lastbegrenzung kann mit dem Job-Klassen-Parameter `CLASS-LIMIT` durchgeführt werden).

8.2.1.5 Prioritätenvergabe

Durch die Vergabe einer – gegenüber der Standardpriorität 255 – höheren Priorität ist die gezielte Bevorzugung einzelner Tasks bei der Aktivierung und besonders hinsichtlich der Benutzung des Betriebsmittels CPU möglich.

In der Regel ist die Vergabe einer mittleren variablen Priorität ausreichend.

Variable Priorität

Die Variation der Priorität sollte je nach Last in 5er- oder 10er-Schritten vorgenommen werden, bis das gewünschte Leistungsziel erreicht ist. Größere Prioritätsabstufungen sind notwendig, wenn:

- viele Tasks aktiv sind
- überwiegend Ein-/Ausgabe-intensive Tasks aktiv sind

Abhängig vom Steuerungsziel werden folgende Werte für die Ersteinstellung empfohlen:

a) Hauptanwendung: TP

Hintergrundanwendungen: Dialog
Batch

Kategorie TP

Handelt es sich um eine DB/DC-Anwendung mit mehreren Tasks, so sollten Datenbanksysteme, die im Multithread-Mode arbeiten (z.B. SESAM/SQL, UDS) eine niedrigere Priorität als die zugehörigen DC-Tasks (UTM, DCAM, ...) erhalten. Die pro Datenbankaufruf erforderliche Kommunikation zwischen den DB- und DC-Tasks kann dadurch deutlich verringert werden.
Sind mehrere TP-Anwendungen unterschiedlicher Wichtigkeit vorhanden, bietet sich eine entsprechende Prioritätsabstufung an.

Empfohlener Prioritätsbereich: 130 - 180

Kategorie DIALOG

Die Dialog-Anwendung soll im Hintergrund laufen. In der Regel erfolgt in dieser Kategorie keine Bevorzugung einzelner Dialog-Tasks.

Empfohlene Priorität: 210

Kategorie BATCH

Für reine Batch-Tasks im Hintergrund genügt die Standard-Priorität. Für die Hervorhebung von Tasks innerhalb der Kategorie reicht die Prioritätsanhebung bis auf 240 aus.

Empfohlener Prioritätsbereich: 240 - 255

b) Hauptanwendung: Dialog

Hintergrundanwendungen: TP
Batch

Kategorie Dialog

Im Allgemeinen werden die Dialog-Tasks gleichrangig behandelt.

Empfohlene Priorität: 180

Kategorie TP

Im Gegensatz zur Einstellung der Kategorieparameter, bei der danach getrachtet wird, Deaktivierungen von TP-Tasks auch im Überlastfall zu vermeiden, soll hinsichtlich der Benutzung des Betriebsmittels CPU die Hintergrundanwendung TP die kleinere Priorität erhalten.

Sollten sich bei den Dialog-Tasks Lasten befinden, die einen dem Batch-Betrieb ähnlichen Charakter haben (Übersetzungen, Programmabläufe innerhalb einer Beantwortungszeit), dann ist wie bei „Hauptanwendung TP“ zu verfahren.

Empfohlene Priorität: 210

Kategorie BATCH

Für den Betrieb als reine Hintergrundlast genügt die Standardpriorität.

Empfohlener Prioritätsbereich: 230 - 255

Im Normalfall werden Batch-Tasks als Hintergrundlast eingesetzt, um freie Betriebsmittel zu nutzen. Alle Tasks der Batch-Hintergrundlast sollten mit der niedrigsten Priorität 255 ablaufen, während alle anderen Tasks Prioritäten von 210 oder besser haben. Damit das System die Nutzung der Betriebsmittel regeln kann, müssen unabhängig davon, ob die Kategorie TP oder Dialog die Hauptanwendung darstellt, die im Hintergrund laufenden Batch-Tasks aus rechenintensiven Programmen bestehen.
Sie müssen ihre Ein-/Ausgaben über die Kanäle und Plattenlaufwerke abwickeln, die von der Vordergrundlast nicht benutzt werden.

Feste Prioritäten

Feste Prioritäten sind für Spezialanwendungen mit extremen Realzeitanforderungen vorgesehen. Dabei sind folgende Gesichtspunkte zu beachten:

Feste Prioritäten engen den Entscheidungsspielraum des Systems stark ein. Zur Aktivierung oder Initiierung anstehende Tasks führen bei voll ausgelasteten Betriebsmitteln zu einer sofortigen Verdrängung anderer Tasks.

Um eine Steigerung des Leistungsverhaltens zu gewährleisten, sollten daher feste Prioritäten nur nach genauer Analyse der Last und der Auslastung der Betriebsmittel zusammen mit lastbegrenzenden Maßnahmen (MAX MPL) eingesetzt werden.

Tasks, denen feste Priorität gegeben wird, sollten nicht abschnittweise oder gänzlich rechenintensiv sein. Auch an ihre Fehlerfreiheit sind erhöhte Anforderungen zu stellen.

8.2.1.6 I/O-Prioritäten-Steuerung für Tasks mit IORM

Normalerweise haben alle Tasks bei der Ausführung von Platten-Ein-/Ausgaben gleiche Priorität.

Eine Ein-/Ausgabe-intensive Anwendung mit niedriger Priorität kann eine andere, höherpriore Anwendung behindern, wenn diese Anwendungen Ein-/Ausgaben auf das gleiche (logische) Gerät ausführen. Behinderungen können auch entstehen, wenn die Ein-/Ausgaben auf verschiedene (logische) Geräte ausgeführt werden, die jedoch auf demselben physikalischen Gerät liegen oder über dieselben Pfade angeschlossen, über dieselben Ports erreichbar oder an denselben Kanälen angeschlossen sind.

IORM kann in der Funktion IOPT (I/O Priority Handling for Tasks) solche Konfliktsituationen erkennen und steuernd in den Ein-/Ausgabe-Betrieb eingreifen. Dazu betrachtet IOPT sowohl den Auslastungsgrad der Ein-/Ausgabe-Einheiten (Geräte, Pfade, Ports und Kanäle) als auch die Ein-/Ausgabe-Prioritäten der nutzenden Tasks.

IOPT unterscheidet drei Ein-/Ausgabe-Prioritäten für Tasks:

- HIGH (hohe Ein-/Ausgabe-Priorität)
- MEDIUM (mittlere Ein-/Ausgabe-Priorität)
- LOW (niedrige Ein-/Ausgabe-Priorität)

Den Task-Kategorien (mit Ausnahme von `SYS`) können mit
`/MODIFY-TASK-CATEGORY IO-PRIORITY=*NONE/*HIGH/*MEDIUM/*LOW`
entsprechende Ein-/Ausgabe-Prioritäten (Attribut `IO-PRIORITY`) zugewiesen werden.

Nähere Informationen zu IORM und IOPT finden Sie im Handbuch „Dienstprogramme“ [7].

8.2.2 Einführung in das PCS-Konzept

Mit PCS (Performance Control Subsystem) steht ein Lastregelungssystem zur Verfügung, das – aufsetzend auf PRIOR – folgende zusätzliche Funktionen bringt:

- verbesserte Bevorzugung von Lastanteilen durch gezielte SERVICE-Zuteilung (der SERVICE eines Servers wird ermittelt aus der Belegungszeit der CPU, Hauptspeicher (MEMORY) und der Anzahl Ein-/Ausgaben (IO))
- erhöhte Transparenz bezüglich der Aufteilung der Serverleistung auf die Kategorien
- dynamische Anpassung der SERVICE-Zuteilung an Kategorien bzw. Tasks bei Lastschwankungen
- Durchsatzkontrolle durch Überwachung der Leistungsaufnahme in den Kategorien
- Differenzierung der Last in „Kurzläufer“ und „Langläufer“ und damit verbesserte Steuerungsmöglichkeiten über automatischen Kategoriewechsel
- Verbesserung des Antwortzeitverhaltens durch Bevorzugung der Kurzläufer
- differenzierte Steuerung von mehreren TP-Anwendungen durch Aufteilung in mehrere Kategorien

Die Arbeitsweise von PCS kann über systemglobale und/oder kategoriespezifische Parameter eingestellt werden:

Kategoriebezogene Steuerparameter

Mit SERVICE-QUOTA (S-Q) wird das Leistungsvermögen des Servers prozentual auf die Kategorien verteilt. Durch SERVICE-QUOTA-MIN und SERVICE-QUOTA-MAX wird ein Rahmen vorgegeben, innerhalb dessen PCS den SERVICE für die angegebene Kategorie plant (S-Q-PLN). Schöpft eine Kategorie ihren Leistungsanteil nicht voll aus, dann steht der Rest anderen Kategorien zur Verfügung.

Über die Dehnung einer Kategorie (Parameter REQUEST-DELAY) erkennt PCS, wie stark die Tasks dieser Kategorie durch die Konkurrenz mit anderen Tasks verzögert werden. Die Dehnung ist also ein Maß für die Belastung und gibt an, um welchen Faktor sich die Laufzeit eines Auftrags verlängert, wenn er – bedingt durch Multiprogrammingbetrieb – auf Betriebsmittelzuteilung warten muss.

$$\text{Dehnung} = \frac{\text{Laufzeit im Multiprogrammingbetrieb}}{\text{Alleinlaufzeit}}$$

Bei gleichzeitigem Einsatz von SM2 und mitlaufendem SM2-Messprogramm SYSTEM für alle Platten, greift PCS periodisch die aktuelle Ein-/Ausgabezeit pro Kategorie ab, wodurch die Genauigkeit der Dehnungsberechnung entsprechend erhöht wird.

Innerhalb eines vorgegebenen Dehnbereichs (REQUEST-DELAY-MIN, REQUEST-DELAY-MAX) passt PCS, abhängig von der aktuellen Belastung (REQUEST-DELAY-ACTUAL), den S-Q-PLN-Wert der Kategorie dynamisch an.

Die SERVICE-Verteilung auf die einzelnen Kategorien geschieht nach folgender Hierarchie:

1. Kategorien mit Dehnbereich und max. Leistungsanteil 100%

   Diese Kategorien erhalten vor allen anderen Kategorien die Leistung zugewiesen („Planwerte“), die ihnen aufgrund der aktuellen Dehnung zusteht.

   Fehlkapazitäten:
   Gibt es mehrere derartige Kategorien und überschreitet die Summe ihrer Planwerte 100%, so werden die Planwerte im Verhältnis so reduziert, dass ihre Summe 100% beträgt.

   Restkapazitäten:
   Beträgt die Summe der Planwerte weniger als 100%, so wird die restliche Kapazität für Kategorien mit und ohne Dehnbereich verplant.
   Sind die Tasks der Kategorien mit Dehnbereich und max. Leistungsanteil 100% nicht in der Lage, die geplante Kapazität zu verbrauchen, so wird die (aktuelle) Restkapazität an die anderen Kategorien mit und ohne Dehnbereich weitergegeben.
   (Ausnahme: volle globale Antwortzeit-Orientierung)

2. Kategorien mit Dehnbereich und max. Leistungsanteil unter 100%

   Kategorien mit Dehnbereich erhalten vor Kategorien ohne Dehnbereich die Leistung zugewiesen, die Kategorien mit Dehnbereich und max. Leistungsanteil 100% übrig lassen und die ihnen davon aufgrund ihrer aktuellen Dehnung zusteht.

   Fehlkapazitäten:
   Gibt es mehrere Kategorien mit Dehnbereich und überschreitet die Summe ihrer Planwerte die noch verfügbare Leistung, so werden die Planwerte im Verhältnis so reduziert, dass ihre Summe der verfügbaren Leistung entspricht.

   Restkapazitäten:
   Beträgt die Summe der Planwerte weniger als die verfügbare Leistung, so wird der Rest für Kategorien ohne Dehnbereich verplant.
   Sind die Tasks der Kategorien mit Dehnbereich nicht in der Lage, die geplante Leistung zu verbrauchen, so werden die (aktuellen) Restkapazitäten den Kategorien ohne Dehnbereich verfügbar gemacht.
   (Ausnahme: volle globale Antwortzeit-Orientierung)

3. Kategorien ohne Dehnbereich

   Kategorien ohne Dehnbereich erhalten die Leistung zugewiesen, die Kategorien mit Dehnbereich übrig lassen. Diese Leistung wird im Verhältnis der maximal vorgesehenen Leistungsanteile auf die Kategorien ohne Dehnbereich verteilt.

Um die Regelungsfunktionen von PCS voll ausschöpfen zu können, sollte stets mindestens eine Kategorie ohne Dehnbereich vorhanden sein.

Zur besseren Differenzierung von Lastanforderungen mit hohem Betriebsmittelbedarf (Langläufern) gegenüber Lastanforderungen mit geringem Betriebsmittelbedarf (Kurzläufern) dient die Funktion „Automatischer Kategoriewechsel“. Dabei gibt man über die Größe DURATION an, wieviele SERVICE UNITs pro Bearbeitungsvorgang maximal verbraucht werden dürfen, bevor ein automatischer Wechsel in die „leistungsschwächere“ Nachfolgekategorie (NEXT CATEGORY) erfolgen soll.
SERVICE UNITs sind die gewichtete Summe der Arbeit der Betriebsmittel CPU, IO und MEMORY.

Durch den Parameter THROUGHPUT-QUOTA wird ein prozentuales Verhältnis bezüglich Antwortzeit- und Durchsatz-Optimierung innerhalb der Kategorie festgelegt. Die Auswirkungen sehen folgendermaßen aus:

	Antwortzeit-Optimierung		**Durchsatz-Optimierung**
THROUGHPUT-QUOTA	voll		voll
	0%	50%	100%

Für Server mit TP- bzw. Dialogbetrieb ist die Antwortzeit-Optimierung wesentlich. In den entsprechenden TP-Kategorien sowie der Dialog-Startkategorie (Kurzläufer) empfiehlt sich der Einsatz von THROUGHPUT-QUOTA=0.

Bei Servern mit vorrangigem Batch-Betrieb ist ein möglichst großer Durchsatz, verbunden mit hoher Auslastung der Betriebsmittel, das wichtigste Leistungsziel. Für durchsatzorientierte Kategorien sind THROUGHPUT-QUOTA-Werte > 50% vorzusehen.

Systemglobale Steuerungsparameter

Die systemglobale Dehnung (REQUEST-DELAY-MAX) stellt einen Schwellwert für die Dehnung aller Tasks, die einer Kategorie mit Dehnbereich angehören, dar. Bei Überschreitung tritt eine Lastbegrenzung ein.

Mit THROUGHPUT-QUOTA wird das prozentuale Aufteilungsverhältnis zwischen Antwortzeit- und Durchsatzoptimierung, bezogen auf das Gesamtsystem, eingestellt. Der Parameter wirkt sich in den Grenzwerten sehr stark aus:

- THROUGHPUT-QUOTA=0
  bewirkt harte Antwortzeit-Optimierung. Dies bedeutet, dass im Überlastfall (bei Überschreitung des systemglobalen REQUEST-DELAY-MAX-Wertes) Hintergrundkategorien vollständig verdrängt werden. Als Folge kann die Auslastung der Betriebsmittel und damit verbunden der Durchsatz absinken.
- THROUGHPUT-QUOTA=100
  wird nur für reinen Batch-Betrieb eingesetzt.

Vorgehensweise beim Einsatz von PCS

Grundsätzlich sollte man vor dem ersten Einsatz die Hardware-Konfiguration (eventuelle Unterkonfiguration gegenüber Lastanforderungen) und die Software-Konfiguration (Lage und Größe der Systemdateien TSOSCAT, Seitenwechselbereiche und SYSEAM) überprüfen.

Je nach Lastfall sollten zunächst die vordefinierten STANDARD-Options

- STD#TP (vorrangiger TP-Betrieb),
- STD#DIA (vorrangiger Dialogbetrieb) und
- STD#BATCH (vorrangiger Batch-Betrieb)

verwendet und die damit erzielten Leistungen vermessen werden (für Einzelheiten zu den STANDARD-Options siehe Handbuch „PCS“ [24]). Gegenüber PRIOR ist dabei ein mindestens gleich gutes, i.d.R. aber besseres Leistungsverhalten zu erwarten. Ergibt die Überprüfung, dass in einzelnen Kategorien Leistungsziele nicht erreicht worden sind, dann muss für diese Kategorien die SERVICE-Planung erhöht werden. Als wesentliches Kriterium ist die aktuelle Dehnung REQUEST-DELAY-ACT zu betrachten (Information mit `/SHOW-PCS-OPTION CATEGORY-NAME=*ALL` bzw. Report „Request delay for category“ der Reportgruppe PCS von SM2).

Für den Transaktions- und Dialogbetrieb empfiehlt sich folgendes schrittweises Vorgehen, um die SERVICE-Vergabe an die betroffenen Kategorien zu erhöhen:

1. Liegt die aktuelle Dehnung zwischen REQUEST-DELAY-MIN und REQUEST-DELAY-MAX, so ist zunächst REQUEST-DELAY-MAX für die entsprechenden Kategorien herunterzusetzen. Dadurch steigt der Wert für SERVICE-QUOTA-PLAN an. Der optimale Arbeitspunkt ist dann erreicht, wenn REQUEST-DELAY-ACT gering unter REQUEST-DELAY-MAX liegt.
2. Der SERVICE-QUOTA-MAX-Wert für die entsprechende Kategorie ist zu erhöhen. Empfohlen wird folgendes Verhältnis:

   $$\frac{\texttt{S-Q-MAX}}{\texttt{S-Q-MIN}} \leq 3$$

3. Der SERVICE-QUOTA-MIN-Wert wird erhöht. Er bewirkt insbesondere eine Reservierung für den Fall plötzlicher Laständerungen.

Bringen diese Maßnahmen nicht den gewünschten Erfolg in Richtung kürzerer Antwortzeiten, dann sind – abhängig von der vorrangigen Betriebsart – weitere Tuning-Maßnahmen erforderlich.

Bei Vorrang des Dialogbetriebs können Langläufer-Transaktionen über folgende Maßnahmen zurückgedrängt werden:

a) S-Q-MAX reduzieren
b) S-Q-MAX reduzieren

} für die Folgekategorie (Dialog1)

Bei Vorrang von TP-Betrieb kann zunächst – über die Verringerung S-Q-MAX und S-Q-MIN für die Kategorie DIALOG – die SERVICE-Planung für die Hintergrundlast Dialog reduziert werden.
Befinden sich in der Kategorie TP mehrere voneinander abhängige Tasks (z.B. UTM/UDS, UTM/SESAM), dann kann zusätzlich die Priorität für diejenigen Tasks mit dem größeren SERVICE-Bedarf erhöht werden.

Sind in der Kategorie TP mehrere Applikationen vorhanden, können die TP-Antwortzeiten generell durch Erhöhung der SERVICE-Planung verbessert werden. Für eine gezielte Verbesserung einzelner Anwendungen empfiehlt es sich, jede Anwendung in einer eigenen TP-Kategorie zu führen.

Soll gewährleistet sein, dass einer Kategorie ggf. die Gesamtleistung des Servers zugeteilt wird, so ist für sie der Wert SERVICE-QUOTA-MAX=100 vorzusehen. Mehreren Kategorien diesen Wert zu geben, ist nicht sinnvoll.

Alle hier aufgeführten Änderungen an den PCS-Standardeinstellungen sind von der Systembetreuung mit dem Dienstprogramm PCSDEFINE durchzuführen. Nachdem PCS als Subsystem gestartet worden ist, können mit Systemkommandos Informationen über PCS ausgegeben sowie dynamische Änderungen an Steuerparametern vorgenommen werden (Details hierzu siehe Handbuch „PCS“ [24]).

Ergänzungen zu PCS ab V2.7:

- Insbesondere um einzelnen Tasks „ausnahmsweise“ eine höhere Service-Zuteilung zukommen zu lassen, wurde das BS2000-Kommando `MOVE-TASK-TO-CATEGORY` eingeführt. Damit können Tasks in eine andere (in JMU definierte) Kategorie versetzt werden.
- Mit dem Kommando `MODIFY-TASK-CATEGORY`, Operand `IO-PRIORITY` können alle Tasks einer Kategorie an die Prioritätssteuerung von überlasteten Platten-Volumes durch IORM angeschlossen werden.

Beispiele für die Wirkung der PCS-Parameter

Beispiel 1

Wirkung der Standard-Option STD#DIA bei vorrangigem Dialogbetrieb zur Programmentwicklung mit einer Batch-Last im Hintergrund.

Parameter der STANDARD-Option STD#DIA:

Kategorie	SERVICE-QUOTA		REQUEST-DELAY		DURATION	NEXT CATEGORY	THROUGH-PUT-QUOTA
	MIN	MAX	MIN	MAX			
TP	0	30	1	3	-	-	-
DIALOG	20	40	2	4	500	DIALOG1	-
DIALOG1	10	30	2	5	2000	DIALOG2	10
DIALOG2	0	50	-	-	-	-	20
BATCH	0	20	-	-	-	-	70
BATCHF	0	20	1	3	-	-	-

Alle ankommenden Dialog-Transaktionen werden zunächst von der Standard-Kategorie DIALOG aufgenommen. Kurze Dialoge, wie z.B. EDT-Anweisungen, benötigen i.d.R. weniger als 200 SERVICE UNITs und verbleiben somit bis zum Transaktionsende in der Kategorie DIALOG.

Ist der SERVICE-Bedarf größer als 500 SERVICE UNITs (z.B. bei Dateioperationen), so erfolgt automatisch der Wechsel in die „leistungsschwächere“ Kategorie DIALOG1.

Compilierungen und Programmtests mit einem SERVICE-Bedarf größer 2.000 SERVICE UNITs wechseln in die Kategorie DIALOG2 über (keine REQUEST-DELAY-Angabe = keine Antwortzeitanforderung) und laufen dort zu Ende.

Gegenüber der durchsatzorientierten Kategorie BATCH (THROUGHPUT-QUOTA=70) für die Batch-Last im Hintergrund, erfolgt eine Bevorzugung der Dialog-Langläufer in der Kategorie DIALOG2 durch den größeren SERVICE-QUOTA-MAX-Wert.

In Ausnahmefällen ist für die Durchführung besonders wichtiger Batch-Läufe die Kategorie BATCHF (BATCH FAST) einzusetzen.

Der Einsatz von PCS bringt gegenüber einem gut eingestellten PRIOR eine wesentliche Verbesserung der Antwortzeiten für kurze Dialoge. Die Antwortzeiten für Dialog-Transaktionen mit einem hohen SERVICE-Bedarf werden verlängert.

Beispiel 2

Wirkung der Standard-Option STD#TP bei vorrangigem TP-Betrieb mit einer Dialog- und Batch-Last im Hintergrund.

Parameter der STANDARD-Option STD#TP:

Kategorie	SERVICE-QUOTA		REQUEST-DELAY		DURATION	NEXT CATEGORY	THROUGH-PUT-QUOTA
	MIN	MAX	MIN	MAX			
TP	50	100	1	3	-	-	-
DIALOG	10	30	2	6	500	DIALOG1	-
DIALOG1	0	30	-	-	-		10
BATCH	0	10	-	-	-	-	70
BATCHF	0	20	1	3	-	-	-

Kategorien mit Angabe einer Dehnung (REQUEST-DELAY) werden bevorzugt vor Kategorien ohne Dehnung.

Übersteigt die Summe der SERVICE-QUOTA-MAX-Werte der Kategorien mit Dehnung 100%, so erfolgt eine entsprechende Normierung, d.h. die relative Konkurrenz der Kategorien zueinander bleibt erhalten.
Durch die explizite Angabe von SERVICE-QUOTA-MAX=100 für TP wird sichergestellt, dass im Bedarfsfall die Hintergrundlast vollständig verdrängt wird.

Sämtliche ankommenden Dialog-Transaktionen gelangen zunächst in die Kategorie DIALOG. Übersteigt der Service-Bedarf 500 SERVICE UNITs, so erfolgt automatisch der Wechsel in die Kategorie DIALOG1, in der keine Antwortzeitanforderungen gestellt werden.

Die Bevorzugung der aufwändigeren Dialog-Transaktionen in DIALOG1 gegenüber dem echten Batch in der Kategorie BATCH erfolgt über den höheren SERVICE-QUOTA-MAX-Wert (=30).

In Ausnahmefällen ist für die Durchführung besonders wichtiger Batch-Läufe die Kategorie BATCHF (BATCH FAST) einzusetzen.

Bei vorrangigem TP-Betrieb führt PCS im Vergleich zu PRIOR zu einer starken Verkürzung der Antwortzeiten der TP-Anwendungen. Auch die Kurzläufer der Hintergrundlast Dialog werden besser bedient, während die Langläufer stark zurückgedrängt werden. Zufriedenstellende TP-Antwortzeiten im Hochlastfall sind unter PRIOR mit variablen Prioritäten nicht erreichbar. Bei Steuerung mit PCS sind alle Leistungsverbesserungen auf einfache Weise mit einem **einzigen Steuerparametersatz** zu erreichen.

Beispiel 3

Steuerung von mehreren TP-Anwendungen

Für eine gezielte Steuerung von TP-Anwendungen wird jede Anwendung oder mehrere gleichrangige Anwendungen in einer eigenen Kategorie geführt. Mit der nachfolgenden Option werden 3 TP-Anwendungen und eine Dialog- und Batch-Last für die Restkapazität gesteuert. Die 3 TP-Anwendungen sind in ihrer Rangfolge den Kategorien TP, TP2 und TP3 zugeordnet.

Die Kategorien TP2 und TP3 müssen mit dem Task-Attribut TP als eigene Kategorien mit der Anweisung DEFINE-JOB-CLASS (siehe Handbuch „Dienstprogramme“ [7]) definiert sein.

PCS-Steuerparameter:

Kategorie	SERVICE-QUOTA		REQUEST-DELAY		DURATION	NEXT CATEGORY	THROUGH-PUT-QUOTA
	MIN	MAX	MIN	MAX			
TP	20	40	1,0	2,5	-	-	-
TP2	15	25	1,0	3,0	-	-	-
TP3	10	15	1,0	3,5	-	-	-
DIALOG	5	10	2,0	5,0	300	DIALOG1	10
DIALOG1	0	30	-	-	0	-	20
BATCH	0	20	-	-	-	-	70
BATCHF	0	5	1,0	4,0	-	-	-

Kategorien mit Angabe einer Dehnung (REQUEST-DELAY) werden bevorzugt vor Kategorien ohne Dehnung. Alle TP-Transaktionen werden aufgrund der besseren Werte für SERVICE-QUOTA und REQUEST-DELAY gegenüber Dialog-Transaktionen vorrangig bedient.

Für die TP-Kategorien wird insgesamt maximal 80 % des Leistungsvermögens des Servers geplant (SERVICE-QUOTA-MAX für TP, TP2 und TP3).

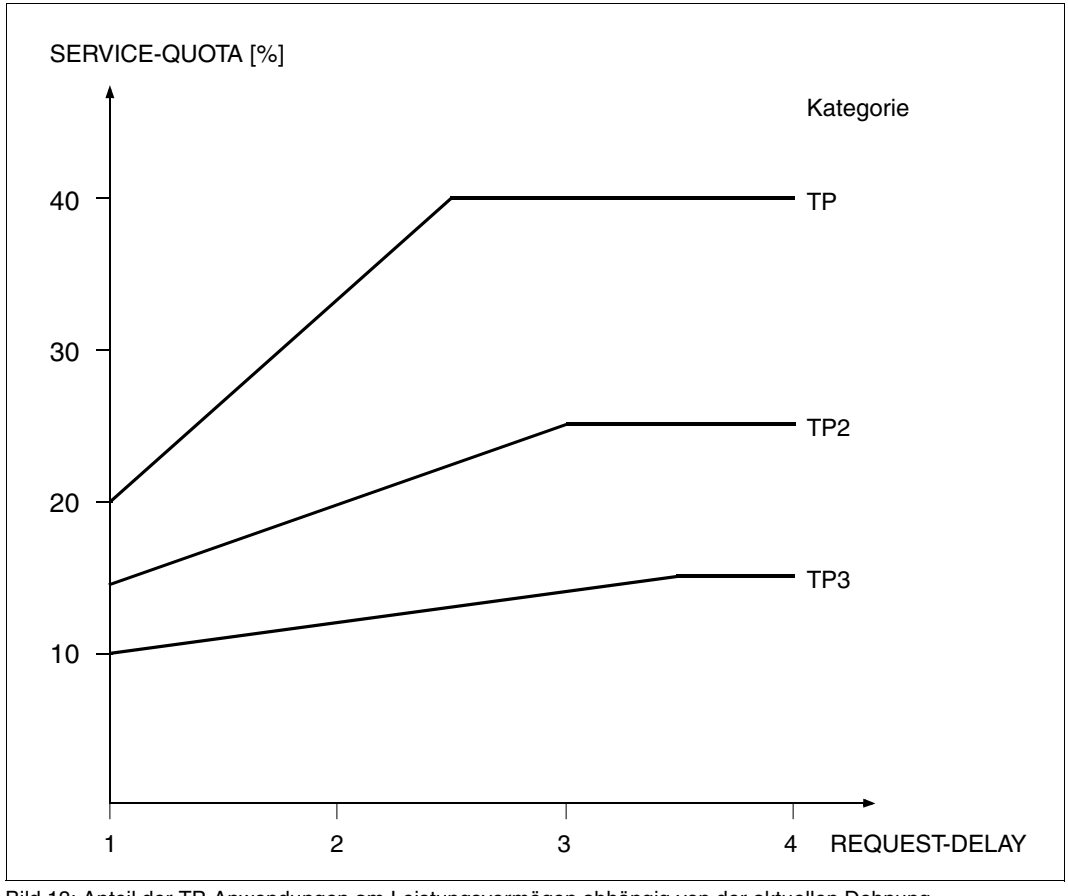

Bild 13: Anteil der TP-Anwendungen am Leistungsvermögen abhängig von der aktuellen Dehnung

Bild 13 zeigt den Anteil am Leistungsvermögen abhängig von der aktuellen Dehnung. Unter wechselnder Belastung (ausgedrückt durch die Dehnung) wird ein wechselnder Anteil am Leistungsvermögen geplant.

Für Anwendungen der Kategorie TP wird bereits bei einer Dehnung von 2,5 (REQUEST-DELAY-MAX) der Wert von SERVICE-QUOTA-MAX (40%) geplant. Liegt der aktuelle Wert der Dehnung zwischen 1 und 2,5, dann wird ein SERVICE zwischen 20% und 40% zugeteilt.

Die Anwendungen der Kategorien TP2 und TP3 werden aufgrund der geringeren Werte für SERVICE-QUOTA und REQUEST-DELAY mit einem entsprechend niedrigeren Anteil am Leistungsvermögen bedient.

Die ankommenden Dialog-Transaktionen werden in der Kategorie DIALOG gestartet. Ist der SERVICE-Bedarf größer als 300 SERVICE UNITs, werden die Dialoge in die leistungsschwächere Kategorie DIALOG1 verdrängt. Durch die Angabe des Werts 10 bei THROUGHPUT-QUOTA für die Kategorie DIALOG wird die Aktivierungspriorität für Dialog-Transaktionen verringert.

Die aufwändigeren Dialog-Transaktionen in der Folgekategorie DIALOG1 werden gegenüber dem echten Batch in der Kategorie BATCH über den höheren SERVICE-QUOTA-MAX-Wert bevorzugt.

In Ausnahmefällen ist für die Durchführung besonders wichtiger Batch-Läufe die Kategorie BATCHF (BATCH FAST) einzusetzen.

Bei größeren Servern mit sehr vielschichtigen Arbeitslasten, rasch wechselnden Leistungsanforderungen und vielen Tasks in Konkurrenz, kann nur noch mit Einsatz von PCS das Leistungsverhalten mit den vorgegebenen Performance-Zielen in Einklang gebracht werden. Je heterogener sich die Arbeitslast zusammensetzt, je größer die Anzahl Tasks und je unterschiedlicher der Betriebsmittelbedarf der einzelnen Lastanteile ist, desto besser kann PCS seine Wirkung entfalten.

8.2.3 Einführung in das TANGRAM-Konzept

Ziel des TANGRAM-Konzepts (Task and Group Affinity Management) ist die bessere Nutzung der Hardware-Leistung von Multiprozessoren.

Zur Überbrückung des Unterschiedes zwischen CPU-Geschwindigkeit und der Zugriffszeit zum Hauptspeicher verwenden alle Server schnelle Pufferspeicher (Caches). Abhängig vom Befehlsprofil (im Wesentlichen vom Anteil der Hauptspeicher-Zugriffe) hängt die erreichbare Leistung stark von der Trefferrate im Cache ab.

Es gibt zwei Arten von Caches, die meist kombiniert werden:

- Store-Through-Caches (STC)
  Die Daten werden so rasch wie möglich „durchgereicht“, d.h. nach einem Schreibvorgang werden die Daten im Hauptspeicher sofort aktualisiert.
- Store-In-Caches (SIC)
  Die Daten verbleiben im Cache und werden nach einer LRU-Strategie (Least Recently Used) in den Hauptspeicher zurückgeschrieben. In diesem Fall sind die im Hauptspeicher stehenden Daten nicht aktuell.

Während bei Monoprozessoren die volle Leistung durch einen ausreichend großen Cache erreicht werden kann, ist die Lage bei Multiprozessoren wesentlich komplexer.

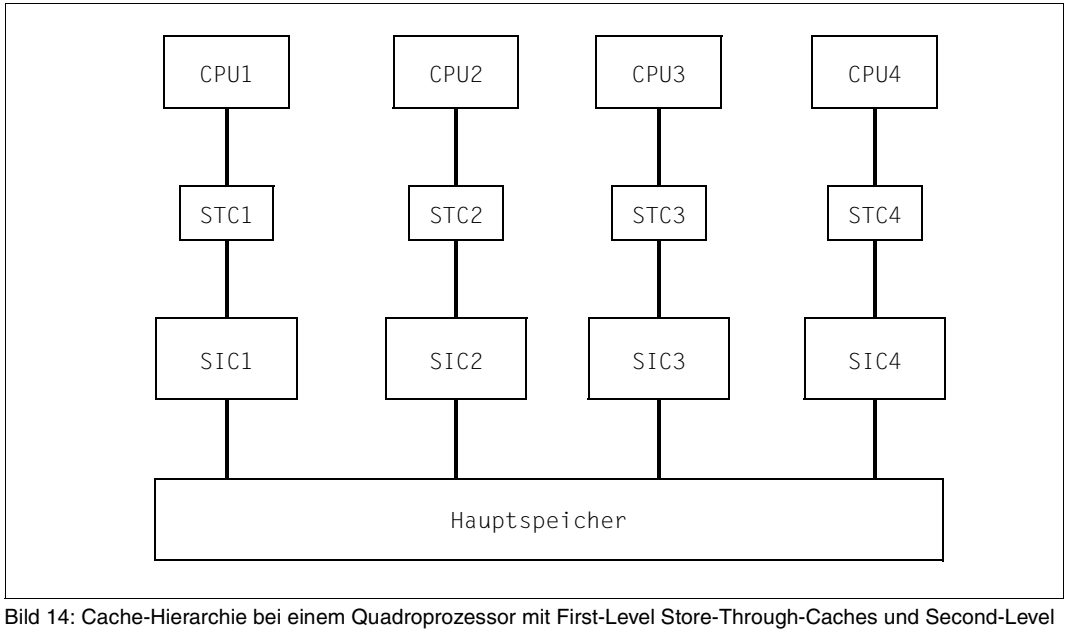

Bild 14: Cache-Hierarchie bei einem Quadroprozessor mit First-Level Store-Through-Caches und Second-Level Store-In-Caches

Je mehr Tasks, die auf verschiedenen CPUs laufen, auf die gleichen Hauptspeicher-Bereiche (z.B. Memory-Pools) zugreifen, desto größer ist die Wahrscheinlichkeit, dass die aktuelle Information sich nicht im CPU-eigenen Cache (SIC), sondern in einem „Nachbar"-Cache befindet.

Damit die CPU weiterarbeiten kann, muss die aktuelle Information erst in den eigenen Cache gebracht werden, wodurch die für den Anwender nutzbare CPU-Leistung sinkt. Die Lage verschärft sich, je größer der Schreibanteil auf die gleichen Hauptspeicher-Seiten wird.

Das TANGRAM-Konzept versucht, diesem Leistungsverlust durch die Bildung von Taskgruppen und deren Zuordnung zu bestimmten CPUs (möglichst einer Untermenge der vorhandenen physikalischen CPUs) entgegenzuwirken.

Bildung von Taskgruppen

Zu einer Taskgruppe werden sogenannte „affine Tasks" zusammengefasst, die eine große Menge von gemeinsamen Daten schreibend referenzieren.

Die Anmeldung zu einer Taskgruppe erfolgt mit dem Makro TINF. Die Verwaltung der Taskgruppen übernimmt das bei „System Ready" automatisch gestartete Subsystem TANGBAS.

Die Softwareprodukte UTM, UDS und SESAM/SQL führen diesen TINF-Aufruf beim Hochfahren pro Appilkation bzw. DB-System automatisch aus. Die Tasks einer UTM-Applikation bilden also eine eigene Taskgruppe.

Zuordnung zu CPUs

Die Zuordnung von Taskgruppen zu CPU-Gruppen erfolgt dynamisch abhängig von der Last, wenn ein längerer Zeitraum betrachtet wird.

Für ein kurzes Zeitintervall (Parameter PERIOD, Default-Wert: 10 Sekunden) dagegen herrscht eine feste Zuordnung, um die erwähnte Cache-Problematik zu entschärfen.

Der **Zuordnungs-Algorithmus** des Subsystems TANGRAM, welches explizit gestartet werden muss, misst periodisch folgende Werte:

- CPU-Verbrauch jeder einzelnen Taskgruppe
- Auslastung der einzelnen CPUs
- CPU-Gesamtauslastung

Anschließend wird eventuell eine neue Zuordnung der Taskgruppen zu den CPU-Gruppen unter folgenden Randbedingungen vorgenommen:

- Die Taskgruppe muss eine gewisse CPU-Mindestleistung aufnehmen (Parameter THRESHOLD, Default-Wert: 10%), um bei der individuellen CPU-Zuordnung berücksichtigt zu werden.
- Lastet eine Taskgruppe einen oder mehrere CPUs weitgehend aus (Parameter CLEARENCE, Default-Wert: 20%, entspricht einer CPU-Auslastung von 80%), so erhält sie jeweils eine CPU mehr zugeordnet, um eine Laststeigerung dieser Taskgruppe im nächsten Zuteilungsintervall nicht zu unterbinden.
- Die Zuteilung der Taskgruppen zu CPUs erfolgt so, dass alle CPUs möglichst gleichmäßig ausgelastet sind.

Der **Scheduling-Algorithmus** von PRIOR überprüft bei jedem Taskwechsel, ob eine Task entsprechend der vom Zuordungs-Algorithmus getroffenen Zuordnung auf der CPU ablaufen darf. Dabei wird die Strategie „IDLE vor Fremd“ verfolgt, d.h. es wird der Leerlauf einer CPU in Kauf genommen, bevor eine fremde Task initiiert wird (die den Cache-Inhalt komplett neu aufbauen müsste).

Nutzen von TANGRAM

Die bessere Nutzung der Hardware-Leistung bei Multiprozessoren hängt von folgenden Bedingungen ab:

- Multiprozessorgrad (höherer Gewinn bei mehr CPUs)
- Hardware-Architektur (große Store-In-Caches)
- Anwendung (Größe des Schreibanteils, Aufteilungsmöglichkeit auf Teilmenge der vorhandenen CPUs)
- Auslastung (merkbarer Gewinn erst bei höherer Auslastung)

Eine allgemeine Aussage über den Nutzen von TANGRAM ist schwierig. Messungen mit verschiedenen Lasten zeigten ein Mehr an verfügbarer Hardware-Leistung von ca. 5% bei Bi-Prozessoren und ca. 10% bei Quadro-Prozessoren.

8.3 Data-Management

Verwaltung der Datenträger und Zugriffswege

Die Geräteverwaltung NDM (Nucleus Device Management) besteht im Wesentlichen aus folgenden Komponenten:

- **Betriebsmittelbelegung**
  Sie steuert und überwacht die logischen Zustände – belegt oder frei – der vom Anwender angeforderten Betriebsmittel (Geräte, Datenträger).
- **Betriebsmittelreservierung**
  Sie bearbeitet die Anforderungen zur Reservierung der Betriebsmittel. Diese Anforderungen formulieren die Anwender mit `/SECURE-RESOURCE-ALLOCATION`.
- **Rekonfiguration**
  Sie ermöglicht dem Operator das Zu- und Wegschalten von Hardware-Einheiten und deren logischen Verbindungen auf Kommandoebene.
- **Datenträgerüberwachung**
  Sie überwacht die Zugriffsbereitschaft der Datenträger, insbesondere bei Montiervorgängen.

Bezüglich des Systemaufwands ist bei der Belegung der Betriebsmittel folgendes zu beachten:

Jede Belegung eines Volumes wird in ihrem Standard-Volume-Label (SVL) hinterlegt. Bei Private-Volumes ergibt sich abhängig von der Belegungsart (task-exclusive oder task-shareable) und vom Belegungszeitpunkt (`ASSIGN-TIME=*USER/*OPERATOR`) ein unterschiedlicher Systemaufwand.

- Bei Bestimmung des Belegungszeitpunkts durch den Anwender und task-exklusiver Belegung mit

  ```
  /SET-DISK-PARAMETER VOLUME=vsn,ASSIGN-TIME=*USER,
       USER-ALLOCATION=*EXCLUSIVE
  ```

  erfolgt bei jeder Dateioperation mit Katalogzugriff (`/COPY-FILE`, `/DELETE-FILE`, `/CREATE-FILE`, `/MODIFY-FILE-ATTRIBUTES`, `OPEN`, `CLOSE`) zu Beginn und am Ende eine Aktualisierung des SVLs auf dem Volume.

- Bei Bestimmung des Belegungszeitpunkts durch den Anwender und task-shareable Belegung mit

  ```
  /SET-DISK-PARAMETER VOLUME=vsn,ASSIGN-TIME=*USER,
       USER-ALLOCATION=*SHARE
  ```

  wird beim Zugriff des ersten Anwenders das SVL gelesen und bei der Freigabe des Volumes durch den letzten Anwender das SVL zurückgeschrieben. Zwischendurch erfolgt also keine Aktualisierung des SVLs auf dem Volume, wohl aber eine interne Tabellenverwaltung bei jeder Dateioperation mit Katalogzugriff.

- Bei Bestimmung des Belegungszeitpunkts durch das System (Einschalt-Interrupt) erfolgt die SVL-Aktualisierung einmal pro Session, unabhängig von der Belegungsart.

Empfehlungen

- Die Bestimmung des Belegungszeitpunkts sollte durch das System erfolgen. Eingestellt wird dies mit

  ```
  /SET-DISK-PARAMETER VOLUME=vsn,ASSIGN-TIME=*OPERATOR,
       USER-ALLOCATION=*EXCLUSIVE/*SHARE
  ```

  Die Freigabe des Volumes (Sonderfall) kann durch Übergang auf

  ```
  /SET-DISK-PARAMETER VOLUME=vsn,ASSIGN-TIME=*USER
  ```

  erreicht werden.

- Bei Shared-Private-Volumes sollte der Parameter `SYSTEM-ALLOCATION=*SHARE` in `/SET-DISK-PARAMETER` nur dann verwendet werden, wenn tatsächlich mehrere schreibberechtigte Systeme auf dieses Volume simultan zugreifen.
  Wie bereits erwähnt (siehe Abschnitt „Logische Betriebsarten von Platten“ ab Seite 163), ist der Koordinierungsaufwand bei Dateioperationen mit Katalogzugriff sehr hoch.

  Sobald im laufenden Betrieb nur noch **ein** System auf ein Shared-Private-Volume zugreift, sollte folgendes Kommando eingegeben werden:

  ```
  /SET-DISK-PARAMETER VOLUME=vsn,SYSTEM-ALLOCATION=*EXCLUSIVE
  ```

9 Systeminterne Abläufe

Zur Erleichterung der Interpretation von Messwerten werden in den folgenden Abschnitten die internen Abläufe im Betriebssystem BS2000, soweit sie für Durchsatz- und Antwortzeitverhalten interessant sind, näher erläutert und verschiedene Richtwerte für die Auslastung der Betriebsmittel angegeben.

9.1 Unterbrechungsanalyse (Funktionszustände)

BS2000/OSD kennt vier Funktionszustände. Davon sind für den normalen Betrieb die Zustände TU, TPR und SIH wesentlich. Im Zustand MEH werden lediglich Maschinenfehler bearbeitet.

Es bedeuten:

TU Task Unprivileged

TPR Task PRivileged

SIH System Interrupt Handling

MEH Machine Error Handling

Die User-Task (das Anwenderprogramm) läuft im Funktionszustand TU.

Systemroutinen, die der User-Task direkt zugeordnet werden können (z.B. SVC: RDATA), werden im Funktionszustand TPR ausgeführt (siehe Bild 15 auf Seite 260).

Die aufgenommene CPU-Zeit im Funktionszustand TU und TPR ist als produktive Zeit im Sinne des Anwenders zu sehen.

Im Funktionszustand SIH laufen die Basissteuermechanismen des BS2000. Außer nach MEH ist der Funktionszustand SIH nicht unterbrechbar.

System-Tasks führen unterstützende organisatorische Aufgaben durch und laufen im Funktionszustand TPR (siehe Bild 16 auf Seite 260).

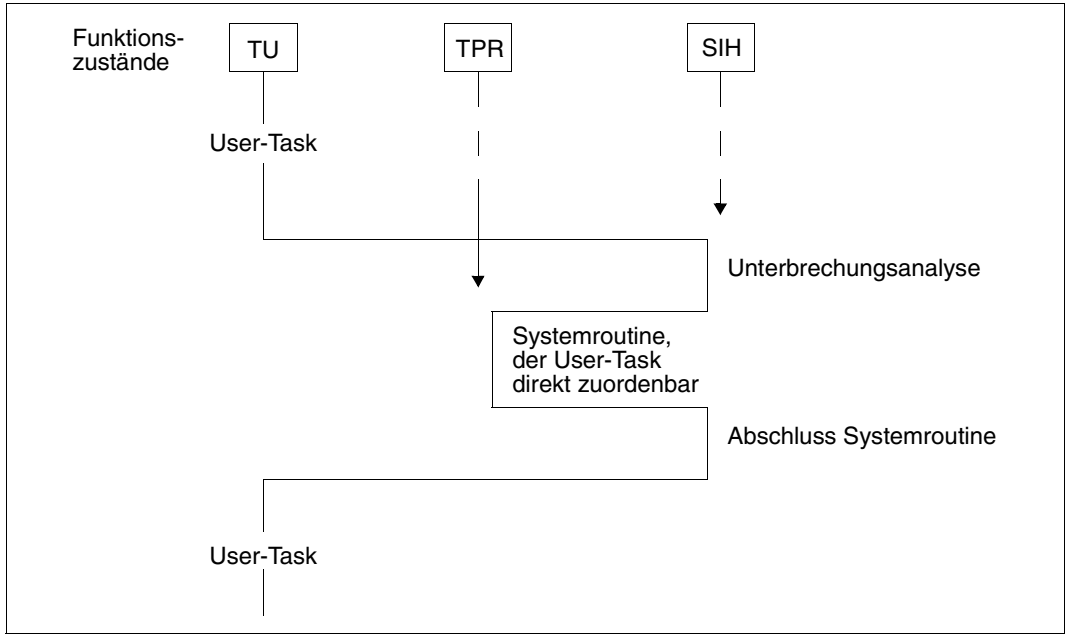

Bild 15: BS2000-Funktionszustände (User-Task)

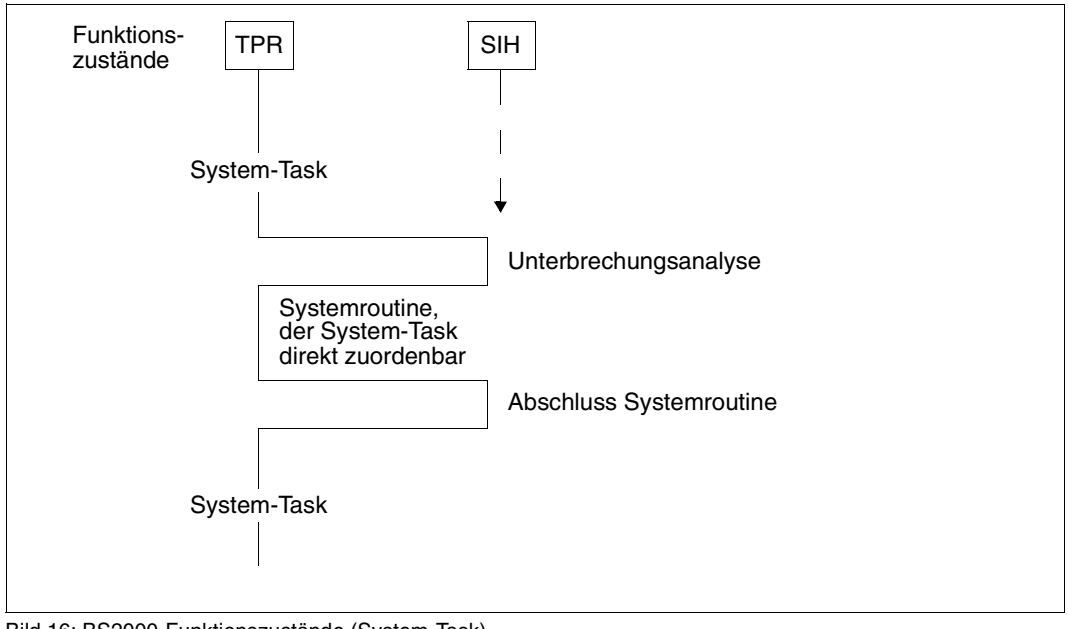

Bild 16: BS2000-Funktionszustände (System-Task)

Eine Unterbrechung tritt entweder dadurch auf, dass eine User- oder System-Task die Unterstützung des Betriebssystems braucht oder, dass ein Ereignis eintritt, das vom Betriebssystem zu behandeln ist.

Es gibt fünf Unterbrechungsarten:

- SVC-Unterbrechung
  (= task-bezogene Unterbrechung)

  Von einer User- oder System-Task werden bestimmte Systemdienste angefordert. Neben dem Aufwand für die Systemroutine werden auch die Unterbrechungsanalyse und der Abschluss der Systemroutine der aufrufenden Task angerechnet.

- Programm-Unterbrechung
  (= task-bezogene Unterbrechung)

  Hierzu zählen die „echten“ Fehler, die zum Programmabbruch führen (Adressenfehler, Datenfehler, ...), die bei Durchsatzüberlegungen nicht weiter betrachtet werden sollen, und die Unterbrechungsursachen:

  – Seite nicht im Speicher (Event-Code: 4C)
  – Adressübersetzungsfehler (Event-Code: 48)

  In beiden Fällen kann zunächst der Programmlauf nicht fortgesetzt werden, da die angesprochene Seite (Page) nicht unmittelbar zur Verfügung steht.

  Beim Event-Code **4C** (Seite nicht im Speicher) sind zwei Fälle zu unterscheiden:

  – Die Seite ist noch im Hauptspeicher, und zwar im Free-Pool (Read Only Queue bzw. Read Write Queue):

    Die über längere Zeit nicht angesprochene Seite wurde durch das Paging-Management in den Free-Pool gebracht. Nach einer einfachen Seitenumkettung kann der Programmlauf fortgesetzt werden (Page-Reclaim). Die globalen Working-Set-Strategien bewirken, dass Page-Reclaims nur noch selten auftreten (siehe Abschnitt „Hauptspeicher-Verwaltung“ auf Seite 267). In den meisten Fällen handelt es sich um den erstmaligen Zugriff auf eine Seite (First-Page-Access).

  – Die Seite ist nicht im Hauptspeicher und muss mit einer Paging-Ein-/Ausgabe in den Hauptspeicher gebracht werden (Page-Read).

  Beim Event-Code **48** handelt es sich um einen echten Fehler bei der Adressübersetzung, der zum Programmabbruch führt.

- Zeitgeber-/externe Unterbrechung
  (= asynchrone Unterbrechung)

  Signal durch den Intervallzeitgeber oder ETC (Elapsed Time Clock).

- Ein-/Ausgabe-Unterbrechung
  (= asynchrone Unterbrechung)

  Signal, dass ein Ereignis bei der Ein-/Ausgabe vorliegt. (In den meisten Fällen handelt es sich um das Eintreten einer Ende-Bedingung bei der Durchführung der Ein-/Ausgabe.)

- Maschinenfehler-Unterbrechung
  (= asynchrone Unterbrechung)

  Signal, dass ein Maschinenfehler aufgetreten ist.

Nach erfolgter Unterbrechungsbehandlung wird mit Ausnahme der SVC-Unterbrechung durch die Dispatcher-Routine (Auswahl-Routine) des Task-Initiators diejenige User- bzw. System-Task mit der höchsten Priorität ausgewählt, die bereit ist zu arbeiten, und ihr die Kontrolle übertragen (Task in control; siehe auch Abschnitt „CPU-Verwaltung“ auf Seite 279).

9.2 Erzeugen und Beenden von Tasks

BS2000/OSD kennt User-Tasks und System-Tasks.

User-Tasks

User-Tasks werden auf Anforderung der Anwender mit Hilfe von System-Tasks erzeugt. Sie untergliedern sich vom Task-Typ her in:

- Dialog-Tasks
  (Task-Typ X'40', erzeugt bei `/SET-LOGON-PARAMETERS` durch die System-Task DIAA)
- Batch-Tasks
  (Task-Typ X'20', erzeugt bei `/ENTER-JOB` durch die System-Task TSC)

Vom Task-Typ zu unterscheiden ist das Task-Attribut. Dieses beeinflusst die Leistungszuweisung im laufenden Betrieb. Entsprechend dem Einsatzzweck gibt es die Task-Attribute

- TP für Transaktionsanwendungen
- DIALOG für Dialoganwendungen
- BATCH für Batch-Anwendungen

Dialog- und Batch-Tasks erhalten automatisch das Task-Attribut DIALOG bzw. BATCH.

Tasks von Transaktionsanwendungen (DCAM, UTM, UDS, SESAM/SQL, ...) laufen unter dem Task-Typ, unter dem sie gestartet werden (als Batch- bzw. Dialog-Task).

Wird eine Job-Klasse definiert mit den Parametern
`TP-ALLOWED=*YES(CATEGORY=xy),START-ATTRIBUTE=*TP,`
so erhalten diese Tasks als zusätzliche Kennzeichnung das Task-Attribut TP
(siehe Abschnitt „Job-Klassen“ auf Seite 217).

Das Task-Attribut TP kann auch mit dem Makroaufruf TINF erlangt werden bei gleichzeitigem Wechsel in die Kategorie mit dem Standardnamen TP.

System-Tasks

System-Tasks (Task-Typ X'80') erhalten automatisch das Task-Attribut SYSTEM.

Es gibt folgende System-Tasks:

- permanent vorhandene (preallocated) System-Tasks:

TSN	Aufgaben
TSC	Erzeugt User-Batch-Tasks
RMM	Hauptspeicher-Prüfung während Startup und Hauptspeicher-Rekonfiguration
PT5	Überwachung der Börsen-Lifetime
PT6	Zeitüberwachung von WHEN-Bedingungen und REPEAT-Jobs
PGE	Paging-Error-Recovery
UCO	Verteilung von Operator-Meldungen, realisiert die Anwendung $CONSOLE
REK	Ausführen von Rekonfigurationsaufträgen
VMM	Speicherbeschaffung für Slotpools und Tabellen der Adressraumverwaltung
MSG	Zuständig für das Meldungswesen
KTT	Ein-/Ausgabe-Treiber für Konsolmeldungen

- wichtige, dynamisch erzeugte (während des Startup oder bei Bedarf) System-Tasks (siehe Handbuch „Systembetreuung“ [11]).

9.3 Verwalten der Betriebsmittel Hauptspeicher und CPU

Sowohl die User- als auch die System-Tasks werden von den Routinen des Task-Managements überwacht und gesteuert.

Damit eine Task zum Ablauf kommen kann, muss das Task-Management folgende Entscheidungen treffen:

- Zuteilung der Berechtigung zur Hauptspeicher-Nutzung → Aktivierung
- Zuteilung des Betriebsmittels CPU → Initiierung

Die Initiierung kann nur für bereits aktivierte Tasks erfolgen.

Kriterien für die Verwaltung des Betriebsmittels **Hauptspeicher**:

- Multiprogramming-Level (MPL) pro Kategorie
- Priorität
- Betriebsmittel-Auslastung (CPU, Hauptspeicher, Paging Aktivität)
- Geleistete Systemdienste (CPU-Zeit, Anzahl Ein-/Ausgaben)

Kriterium für die Verwaltung des Betriebsmittels **CPU** ist ausschließlich die

- Priorität

Ist bei Multiprozessoren die Funktion TANGRAM eingeschaltet, so kann der Zuordnungs-Algorithmus eventuell für eine andere Initiierungsreihenfolge sorgen (siehe auch Abschnitt „Einführung in das TANGRAM-Konzept“ auf Seite 254).

Interne Kategorie-Bezeichnung

Systemintern werden sowohl die Task-Kategorien als auch die Prioritäten etwas anders dargestellt als an der Benutzerschnittstelle.

Kategorien mit Standard-Kategorienamen haben feste Bezeichnungen:

Kategorie	Kategorie-Kennzeichen
SYS	0
DIALOG	1
BATCH	2
TP	3
xy	4
. . .	. . .

Interne Priorität

Für die vergebenen variablen Prioritäten erfolgt eine Gewichtung entsprechend der Wichtigkeit der Kategorie (repräsentiert durch den Parameter WEIGHT-CODE). Die variable interne Priorität ist eine Funktion

- der externen Priorität
- des Gewichts `W` (WEIGHT-CODE) der Kategorie, zu der die Task gehört
- der Summe der Gewichte aller Kategorien

$$W_{SYS} + W_{TP} + W_{DIAL} + W_{BATCH} + W_{xy} + \ldots$$

Variable interne Priorität =

$$1 + (256 - \text{externe Priorität}) \bullet \frac{1}{2}\left(1 + \frac{W}{W_{SYS} + W_{TP} + W_{DIAL} + W_{BATCH} + W_{xy} + \ldots}\right)$$

Vom Anwender vergebene, feste externe Prioritäten werden folgendermaßen umgerechnet:

$$\text{Feste interne Priorität} = 256 - \text{externe Priorität}$$

Die interne Priorität ist die Basis für die Berechnung der Aktivierungs- und Initiierungs-Priorität.

9.3.1 Hauptspeicher-Verwaltung

Folgende Begriffe werden erläutert:

- Aktivierung (siehe Seite 268)
  Zuteilung der Berechtigung zur Hauptspeicher-Nutzung an eine arbeitswillige, ablaufbereite (inactive, ready) Task
- Deaktivierung (siehe Seite 270)
  Entzug des Rechts auf Hauptspeicher-Nutzung bei Erwartung langer Wartezeiten oder nach Ableistung bestimmter Systemdienste
- Zwangsdeaktivierung (siehe Seite 271)
  Zwangsweise Deaktivierung einer Task aufgrund von Betriebsmittelüberlastungen (Forced Deactivation)
- Verdrängung (siehe Seite 272)
  Aktivierung einer Task auf Kosten der Deaktivierung einer anderen Task (Preemption)
- Kontrollfunktionen der Hauptspeicher-Verwaltung (siehe Seite 273)
  - Activation Control Function (ACF)
  - Preemption Control Function (PCF)
  - Paging Load Control Function (PLC)
  - System Service Slice Runout Control
  - Waiting Time Runout Control
- Seitenverwaltungs-Algorithmus (siehe Seite 277)
  - System Working Set-Verfahren (SYS-WS)

Alle oben genannten Begriffe, bis auf den Punkt „Seitenverwaltungs-Algorithmus“, sind nur im seltenen Fall eines Hauptspeicher-Engpasses von Bedeutung.

Aktivierung

Eine Aktivierung ist nur möglich, wenn von der Kontrollfunktion ACF (Activation Control Function) aufgrund der Messung der Auslastung der Betriebsmittel CPU und Hauptspeicher sowie der Paging-Aktivität (siehe „Kontrollfunktionen der Hauptspeicher-Verwaltung“ auf Seite 273) die Aktivierung erlaubt wird.

Vorrangiges Ziel ist es, den vom Anwender spezifizierten **MIN MPL-Wert** (MINIMUM-ACTIVE-TASKS) **in jeder Kategorie zu erreichen.**

Der Parameter WEIGHT-CODE beeinflusst den Aktivierungsvorgang.

Eine Index-Entscheidung (mit NAT (Number Active Tasks) = Anzahl der aktiven Tasks der Kategorie, für die der Index berechnet wird) erfolgt, wenn eine dieser drei Aussagen zutrifft:

- noch nicht alle Kategorien haben MIN MPL erreicht
- in jeder Kategorie ist MIN MPL überschritten, aber MAX MPL noch nicht erreicht
- in jeder Kategorie ist MAX MPL bereits überschritten

Der Kategorie-Index wird wie folgt berechnet:

$$\text{Kategorie-Index} = \frac{\text{NAT} + 1 - \text{N}}{\text{WEIGHT}}$$

mit:

$N = 0$, wenn $MPL < MIN\ MPL$

$N = MIN\ MPL$, wenn $MIN\ MPL \leq MPL < MAX\ MPL$

$N = MAX\ MPL$, wenn $MAX\ MPL \leq MPL$

Die Aktivierung erfolgt für die Kategorie mit dem kleinsten Index. Von dieser Kategorie wird die Task mit der höchsten Aktivierungspriorität ausgewählt.

Ausnahme
Ist der MIN MPL-Wert der ermittelten Kategorie bereits erreicht und liegt eine Aktivierungsanforderung einer Task mit fester Priorität aus einer anderen Kategorie vor, so wird diese aktiviert, sofern die Kontrollfunktion ACF dies gestattet; andernfalls kommt es zu einer Verdrängung.

Tasks mit Systemprioritäten werden immer sofort aktiviert. Auch hier entscheidet die Kontrollfunktion ACF, ob dies im Rahmen einer Aktivierung möglich ist oder ob eine Verdrängung durchgeführt werden muss.

Aktivierungspriorität

Bei variablen externen Prioritäten hängt die Aktivierungspriorität von vier Faktoren ab:

- von der variablen internen Priorität
- vom Funktionszustand (TU oder TPR)
- vom Zeitpunkt t_A der letzten Aktivierung (es wird jeweils die Differenz Δ gebildet)
- von einem Konfigurationsfaktor

$$\text{Variable Aktivierungspriorität} = (\text{Variable interne Priorität} + P) \bullet \frac{\Delta t_A(\text{Elapsed-Time})}{\Delta t_A(\text{CPU-Time}) \bullet C}$$

Tasks, die auf Zuteilung der Berechtigung zur Hauptspeicher-Nutzung warten und sich im Funktionszustand TPR befinden, erhalten eine durch die Konstante P ausgedrückte höhere Aktivierungspriorität.

$$P = \left\{ \begin{array}{l} 5, \text{ falls in TPR} \\ 0, \text{ falls in TU} \end{array} \right\}$$

Der Konfigurationsfaktor C hängt vom Server-Typ ab und wird dynamisch mit steigender Paging-Rate erhöht.

```
Feste Aktivierungspriorität = Feste interne Priorität
```

Deaktivierung

Die Deaktivierung von aktiven Tasks dient dazu, ablaufbereiten inaktiven Tasks das Betriebsmittel Hauptspeicher zugänglich zu machen.

Kriterien für die Deaktivierung aktiver Tasks:

- Die weitere Verarbeitung ist nicht möglich,
  z.B. durch Warteaufrufe im Programm (`PASS`, `VPASS`) oder Warten auf Terminal-Eingabe beim Dialogbetrieb (`WRTRD`, `RDATA`).
- Wartezeiten beim Warten auf Ereignisse werden überschritten,
  z.B. durch Warten auf Terminal-Eingabe beim TP-Betrieb:

  DCAM: `YRECEIVE`
  UTM: `KDCWAIT`

  Task-Kommunikation
  ITC: `REVNT`
  TU-Eventing: `SOLSIG`
  Forward-Eventing: `RSOFEI`

  (siehe „Kontrollfunktionen der Hauptspeicher-Verwaltung“, Punkt „Waiting Time Runout Control“ auf Seite 276).
- Gewisse Systemdienste in Form von CPU-Zeit und Anzahl Ein-/Ausgaben wurden geleistet
  (siehe „Kontrollfunktionen der Hauptspeicher-Verwaltung“, Punkt „System Service Slice Runout Control“ auf Seite 275).

Die Deaktivierung unterbleibt, wenn die Funktion „No Deactivation“ (Makro `TINF`, Parameter `DEACT`) eingeschaltet ist.
Ausnahme: Der Warteaufruf `VPASS n` führt immer zur Deaktivierung.

Zwangsdeaktivierung

Die Zwangsdeaktivierung von Tasks erfolgt, wenn von der Kontrollfunktion ACF (Activation Control Function) eine zu hohe Auslastung der Betriebsmittel CPU und Hauptspeicher bzw. eine zu hohe Paging-Rate in Abhängigkeit des CPU-Typs festgestellt wird (Matrix-Entscheidung).

Innerhalb eines ACF-Messintervalls wird jeweils nur eine Task deaktiviert.

Zur Bestimmung der Kategorie, aus der eine Task zwangsdeaktiviert werden soll, sind folgende Kategorie-Attribute maßgebend:

- MIN MPL
- MAX MPL
- WEIGHT

Durch Vorgabe entsprechend hoher Werte von MIN MPL und WEIGHT für Kategorien mit wichtigen Anwendungen muss dafür gesorgt werden, dass nur Tasks aus „weniger wichtigen“ Kategorien deaktiviert werden.

Für die Zwangsdeaktivierung kommen in erster Linie Tasks mit niedriger Priorität in Frage, die erst dabei sind, ihren Working-Set aufzubauen. Dadurch hält man vergeblich geleistete Aufwände des Systems auf einem Minimum.

Von einer Zwangsdeaktivierung sind ausgeschlossen:

- Tasks mit fester Priorität
- Tasks im Funktionszustand TPR
- Tasks, die die Funktion „No deactivation“ eingeschaltet haben

Verdrängung

Zu einer Verdrängung (Preemption) kann es kommen, wenn eine Aktivierungsanforderung vorliegt, aber die Kontrollfunktion ACF aufgrund der Auslastung der Betriebsmittel CPU und Hauptspeicher sowie der Höhe der Paging-Rate keine zusätzliche Aktivierung mehr zulässt.

Preemptions werden in der Reportgruppe PRIOR-ACF von openSM2 ausgewiesen. Sie sollten unbedingt vermieden werden. Ursache kann sein, dass:

- die MIN MPL-Werte zu hoch eingestellt sind
- zu viele Tasks mit fester Priorität laufen

Zwei Möglichkeiten der Verdrängung werden unterschieden:

a) Preemption zwischen **verschiedenen** Kategorien

Die aktive Task A wird durch eine inaktive Task B verdrängt, die einer anderen Kategorie angehört. Dies tritt ein, wenn:

– für die Kategorie, der die inaktive Task B angehört, gilt: MPL < MIN MPL

– und gleichzeitig für die Kategorie der aktiven Task A: MPL > MIN MPL

Die Preemption von Tasks verschiedener Kategorien läuft folgendermaßen ab:

1. Aktivierung einer Task aus einer Kategorie mit MPL < MIN MPL und dem kleinsten Kategorie-Index. Die höchstpriore Task aus dieser Kategorie wird aktiviert.
2. Zwangsdeaktivierung einer Task aus einer Kategorie mit MPL > MIN MPL (siehe „Zwangsdeaktivierung“ auf Seite 271).

b) Preemption innerhalb der **gleichen** Kategorie

Die aktive Task A und die inaktive Task B gehören der gleichen Kategorie an. Dies ist nur möglich, wenn:

– die inaktive Task B eine feste Priorität hat

– und die aktive Task A eine variable Priorität hat

Die Preemption von Tasks innerhalb der gleichen Kategorie läuft folgendermaßen ab:

1. Zwangsdeaktivierung einer Task dieser Kategorie mit variabler Priorität (siehe „Zwangsdeaktivierung“ auf Seite 271).
2. Aktivierung der Task mit der festen Priorität.

Kontrollfunktionen der Hauptspeicher-Verwaltung

- Activation Control Function (ACF)

  ACF misst periodisch die Auslastung der Betriebsmittel CPU und Hauptspeicher sowie die Paging-Aktivität (→ INVOCATION LONG = INVOCL, siehe Reportgruppe PRIOR-ACF von openSM2).
  In Abhängigkeit von der CPU-Auslastung liegt das Aufrufintervall zwischen 0,25 und 2 Sekunden.

  CPU-UTILIZATION

  Die Größe wird aus der im Intervall gemittelten CPU-Auslastung und der Wartezeit auf Zuteilung der CPU errechnet.

  MEMORY-UTILIZATION

  Verhältnis des vom System geschätzten Working-Set-Bedarfs für alle aktiven Tasks (als Summe der PPC-Werte) zur Anzahl der für Paging verfügbaren Seiten (NPP = Number Pageable Pages).

  PAGING-UTILIZATION

  Höhe der Paging-Rate.

  Die gemessenen Werte werden in folgende Klassen eingeteilt:

  – H (High)
  – M (Medium)
  – L (Low)

  Die UTILIZATIONs sind in der Reportgruppe PRIOR-ACF von openSM2 enthalten. Die Festlegung der Grenzwerte für die Klassen ist abhängig vom Server (CPU-Geschwindigkeit, Hauptspeicher-Ausbau) und wird beim Startup vorgenommen.

  Je nach Betriebsmittelauslastung und vergebenen Kategorie-Attributen bzw. Task-Prioritäten erfolgt anhand einer Matrix die Entscheidung, ob eine weitere Aktivierung zulässig ist oder ob eine Zwangsdeaktivierung, eine Verdrängung oder gar keine Aktion erfolgen soll.

  Vor der eigentlichen Aktivierung einer Task nimmt ACF eine zusätzliche Messung vor, die aber nur die Hauptspeicher-Auslastung betrifft, um sicherzustellen, dass die Auslastung des Hauptspeichers eine weitere Aktivierung zulässt
  (→ INVOCATION SHORT = INVOCS, siehe Reportgruppe PRIOR-ACF von openSM2).

- Preemption Control Function (PCF)

  Task-Verdrängungen auf Aktivierungsebene sind aufwändig, da ggf. der Working-Set der verdrängten Task bei der Wiederaktivierung neu aufgebaut werden muss. Um den dadurch entstehenden Overhead gering zu halten, strebt das System eine möglichst kleine Verdrängungsrate an.

  PCF überwacht periodisch die geglättete Verdrängungsrate pro Intervall. Das Aufrufintervall liegt – abhängig vom Maschinentyp – zwischen 20 und 48 Sekunden.
  Tritt während dieses Intervalls mindestens eine Verdrängung auf, so wird die MAX MPL OPTION eingeschaltet. Dies bedeutet, dass der Wert für MAX MPL ab diesem Zeitpunkt als harte Grenze anzusehen ist, über die hinaus nicht aktiviert wird. (Die Ausschaltung der MAX MPL OPTION erfolgt, wenn über mehrere Intervalle hinweg keine Verdrängung auftritt.)

  PCF will die Verdrängungsrate niedrig halten. Dazu führt PCF Verdrängungsanforderungen möglichst nicht als Verdrängungen, sondern als zusätzliche Aktivierungen durch. Dies wird erreicht, indem PCF Hauptspeicher-Bereiche für Verdrängungsanforderungen reserviert, wenn eine bestimmte Verdrängungsrate pro Intervall (Preemption-Limit) überschritten wird.

  Der für Verdrängungsanforderungen reservierte Hauptspeicher wird mit steigender Verdrängungsrate stufenweise vergrößert (5 bis 15% des realen Hauptspeicher-Ausbaus, abhängig von der Hauptspeicher-Größe). Damit wird den übrigen Tasks, die keine Verdrängungsanforderung stellen, eine höhere Hauptspeicher-Auslastung vorgetäuscht, sodass deren Aktivierung unterbleibt und genügend Hauptspeicher für Tasks **mit** Verdrängungsanforderung zur Aktivierung zur Verfügung steht.

  Das System kennt 4 Stufen (Preemption-Level 0 bis 3), die mit der Meldung `EXC0455 TASK PREEMPTION LEVEL=(&00)` angezeigt werden:

  Level 0 Normalzustand (Verdrängungsrate < Preemption-Limit)

  Level 1, 2 Kurzfristige Überlastzustände
  Der Preemption-Level wird immer erhöht, wenn
  – Verdrängungsrate > Preemption-Limit
  – Verdrängungsrate im Intervall n + 1 > Verdrängungsrate im Intervall n

  Level 3 Langfristiger Überlastzustand (Dieser kann durch zu hohe Einstellung der MIN MPL-Parameter hervorgerufen werden: Tasks von Kategorien, die MIN MPL noch nicht erreicht haben, stellen grundsätzlich eine Verdrängungsanforderung.)
  Der Operator wird informiert, dass Preemption-Level 3 erreicht ist und erhält ab diesem Zeitpunkt Meldung über jede Änderung des Preemption-Levels. Stellt das System mit Hilfe des geglätteten Multiprogramming-Grades fest, dass die MIN MPL-Parametereinstellung zu hoch ist, so wird der Operator aufgefordert, die MIN MPL-Parametereinstellung zu überprüfen und den MIN MPL-Wert geeigneter Kategorien zu senken.

Bei Absinken der Verdrängungsrate wird der reservierte Hauptspeicher stufenweise zurückgegeben. Zu dem Zeitpunkt, an dem der Normalzustand wieder erreicht ist, erhält der Operator die Meldung:

```
EXC0456   PREEMPTION CONTROL FUNCTION TERMINATED
```

Werden Preemption-Meldungen ausgegeben, sollte in jedem Fall Abhilfe geschaffen werden (siehe „Verdrängung“ auf Seite 272).

- Paging Load Control Function (PLC)

  PLC führt langfristige Messungen (Aufrufintervall 20 bis 48 Sekunden in Abhängigkeit von der CPU-Geschwindigkeit) der Paging-Aktivitäten durch und kann als Ergänzung zu ACF gesehen werden.
  Während ACF die aktuelle Paging-Rate misst und mit den vorgegebenen Grenzwerten vergleicht, um daraus kurzfristige Entscheidungen abzuleiten, beeinflusst PLC die beim Startup festgelegten Grenzwerte in Abhängigkeit von der Lastzusammenstellung.

  Ist die Last dialogorientiert, werden höhere Paging-Aktivitäten zugelassen gegenüber einer Last, die TP- oder TP/Batch-orientiert ist. Damit wird erreicht, dass TP-orientierte Lasten durch Paging-Aktivitäten möglichst nicht beeinträchtigt werden bzw. dass bei batch-orientierter Last der Durchsatz optimiert wird.

  PLC führt eine Statistik, wie oft hinsichtlich der Paging-Aktivitäten der Zustand

  – Underload
  – Mediumload
  – Overload

  pro Aufrufintervall auftritt. Tritt einmal pro Aufrufintervall der Zustand Overload auf, so wird die MAX MPL OPTION eingeschaltet. Die MAX MPL OPTION wird ausgeschaltet, wenn über mehrere Intervalle hinweg der Zustand Paging-Overload nicht auftritt, der Preemption-Level 0 herrscht und die Preemption-Rate < 1 ist.

- System Service Slice Runout Control

  Die „System Service Slice“ dient zur Aufsummierung der Systemdienste, die eine aktive Task in Form von CPU-Zeit (im Funktionszustand TU + TPR) und von durchgeführten Ein-/Ausgaben erhalten hat.

  Der Systemservice wird nach der Formel `SERVICE = (A * B * C) + D` berechnet, mit:

  A: Mittlere Befehlsausführungszeit (abhängig von der CPU-Geschwindigkeit)

  B: Mittlere Befehlsanzahl pro Ein-/Ausgabe-Anforderung

  C: Anzahl der Ein-/Ausgaben seit der letzten Aktivierung

  D: CPU-Zeit seit der letzten Aktivierung

Die Größe der „System Service Slice“ ist kategorie- und Server-abhängig.

Das Aufrufintervall für System-Service-Slice-Runout-Control beträgt 2 Sekunden.

Für die Ergreifung von Maßnahmen wird bei System-Service-Slice-Runout unterschieden, ob sich die Task im Funktionszustand TU oder TPR befindet:

– System Service Slice Runout – Funktionszustand TU

  Die Deaktivierung erfolgt nur dann, wenn in der **gleichen** Kategorie eine ablaufbereite Task (Status: inactive, ready) mit höherer Priorität vorhanden ist.

– System Service Slice Runout – Funktionszustand TPR

  Wenn in der gleichen Kategorie eine ablaufbereite Task (Status: inactive, ready) mit höherer Priorität vorhanden ist, erfolgt eine Deaktivierung erst beim 2. Auftreten von System-Service-Slice-Runout. Tritt die Task nach dem ersten Runout in den Zustand TU, dann wird sie sofort so wie oben beschrieben behandelt.

- Waiting Time Runout Control

  Die Funktion „Waiting Time Limit“ wird zur Überwachung der Tasks verwendet, die auf ein Ereignis warten (Börsen- oder ITC-Ereignisse) und dabei Hauptspeicher belegen.

  Der Aufruf von „Waiting Time Runout Control“ erfolgt nur dann, wenn mehr als 25 % des seitenwechselbaren Hauptspeichers durch Tasks belegt werden, die auf Börsen-Ereignisse (z.B. DCAM: YRECEIVE, UTM: KDCWAIT, TU-Eventing: SOLSIG, Forward-Eventing: RSOFEI) oder ITC-Ereignisse (Inter-Task-Communication: REVNT) warten. Das Aufrufintervall bewegt sich in Abhängigkeit von der Hauptspeicher-Auslastung zwischen 1 und 7 Sekunden.

  Wird das Waiting-Time-Limit für eine oder auch mehrere Tasks überschritten, so erfolgt die Deaktivierung in folgender Weise:

  Tasks mit variabler Priorität, die einer Kategorie angehören, deren MPL > MIN MPL ist, werden zuerst deaktiviert (sofern die Deaktivierung bei Waiting-Time-Runout erlaubt ist: Parameter DWTR im TINF-Makro).
  Das Verfahren wird abgebrochen, sobald der von den wartenden Tasks gebundene seitenwechselbare Hauptspeicher die 25%-Grenze unterschreitet.

  Reicht diese Maßnahme nicht aus, um die 25%-Grenze zu unterschreiten, so wird der Deaktivierungsvorgang auf wartende Tasks mit fester Priorität ausgedehnt sowie auf Kategorien, deren MPL-Wert < MIN MPL ist (sofern die Deaktivierung erlaubt ist). Unabhängig von der 25%-Grenze werden alle Tasks deaktiviert, die länger als 30 Sekunden warten und die genannten Bedingungen erfüllen.

Seitenverwaltungs-Algorithmus (System Working Set-Verfahren, SYS-WS)

Das Verfahren verwaltet die Hauptspeicher-Seiten global, wobei die Einteilung entsprechend ihrem „Zugriffsalter“ in vier Gruppen erfolgt:

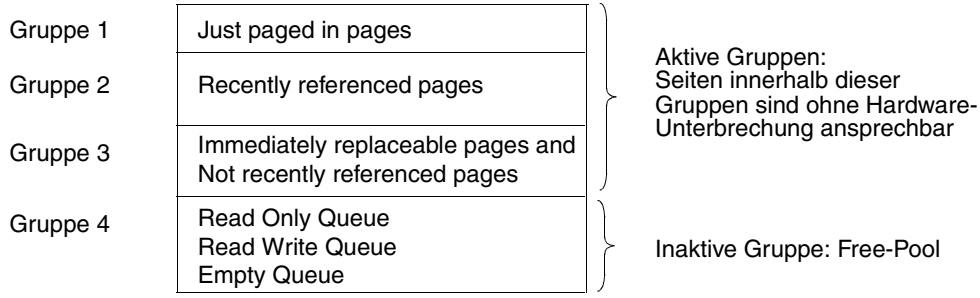

Die Seiten jeder Gruppe sind miteinander verkettet.

Prinzipieller Ablauf

Beim Auftreten des Ereignisses „Seite nicht im Hauptspeicher“ (Page Fault) wird ein Seitenrahmen aus der Gruppe 4 mittels Paging-Ein-/Ausgabe (Page Read) mit der angeforderten Seite gefüllt und nach Gruppe 1 gebracht (Gruppen-Übergang 4 $\rightarrow$ 1; Reference-Bit=ON).

Grundsätzlich wird versucht, möglichst viele Seiten aktiv zu halten. Der Free-Pool ist daher relativ klein. Eine gewisse Minimalgröße zur Befriedigung schnell aufeinander folgender Seitenanforderungen ist jedoch notwendig.

Bei Erreichen der Minimalgröße erfolgt der Anstoß einer Routine zur Auffüllung des Free-Pools mit Seiten aus Gruppe 3 (Gruppen-Übergang 3 $\rightarrow$ 4).

Seiten mit Reference-Bit=ON werden an das Ende der Kette von Gruppe 2 gebracht und das Reference-Bit gelöscht.

Seiten, die zwei mal hintereinander mit Reference-Bit=OFF angetroffen werden, kommen in die Gruppe 4.

Die Durchsuchung der Gruppe 3 erfolgt solange, bis die benötigte Anzahl Seiten zur Auffüllung des Free-Pools gefunden ist.

Enthält Gruppe 3 nicht genügend freigebbare Seiten, so erfolgt die Auffüllung von Gruppe 3, indem sämtliche Seiten von Gruppe 2 nach Gruppe 3 gebracht werden (Gruppen-Übergang 2 $\rightarrow$ 3).

Ebenso wird die nun leere Gruppe 2 wieder aufgefüllt durch Umkettung sämtlicher Seiten von Gruppe 1 nach Gruppe 2 (Gruppen-Übergang 1 $\rightarrow$ 2).

Da die Seitenanforderungen sowohl für die automatische Auffüllung der Gruppe 1 sorgen, als auch den Seitenersetzungs-Algorithmus anstoßen, ergibt sich ein konsistenter Zustand.

Der einfache Algorithmus des SYS-WS-Verfahrens führt zu einer Aufwandsreduzierung im Paging-Management, aber auch zu einer „gröberen“ Bestimmung des Working-Set-Bedarfs der einzelnen Tasks. Die Aufwandsreduzierung macht sich besonders bei großem Hauptspeicher bemerkbar.

Wird eine Task deaktiviert, so behält sie auch im inaktiven Zustand ihren Working-Set. Wird die Task erneut aktiviert, sind keine Page-Reclaims zur Wiederbeschaffung ihres Working-Sets notwendig.

Das SYS-WS-Verfahren kennt zwar den UPG-Wert (Used-Pages) jeder Task, hat jedoch keine Möglichkeit festzustellen, in welcher Phase sich die Task befindet (auch inaktive Tasks haben einen UPG-Wert $\neq 0$).

Die Bestimmung des PPC-Wertes (Planned Page Count) erfolgt daher näherungsweise durch einen Vergleich des UPG-Wertes mit einem angenommenen, vom Kategorietyp abhängigen, mittleren Working-Set-Wert.

Da möglichst viele Seiten aktiv gehalten werden, liegt der Summen-UPG-Wert praktisch immer in der Größenordnung des verfügbaren seitenwechselbaren Hauptspeichers und hat nur begrenzte Aussagekraft. Der Working-Set-Bedarf wird ausschließlich durch den PPC-Wert ausgedrückt. Der Wert ist eine grobe Schätzung. Bei den heute üblichen großen Speicherausbauten ergeben sich Vorteile dadurch, dass die Aufwände für die ohnehin nicht benötigte genaue Abschätzung des Speicherbedarfs unterbleiben.

9.3.2 CPU-Verwaltung

Folgende Begriffe werden verwendet:

- Initiierung
  Zuteilung des Betriebsmittels CPU an eine aktive, ablaufbereite Task (die sich im Zustand „active, ready“ befindet).
- Deinitiierung
  Entzug des Betriebsmittels CPU bei Erwartung von Wartezeiten (Übergang in den Zustand: „active, not ready“).
- Verdrängung
  Deinitiierung einer Task, gefolgt von der Initiierung einer höherprioren Task.
- Kontrollfunktion der CPU-Verwaltung
  - Micro Time Slice (MTS)

Initiierung

Die Dispatcher-Routine des Task-Initiators wählt aus der Anzahl der aktiven, ablaufbereiten Tasks die Task mit der höchsten Initiierungspriorität aus und überträgt ihr die Kontrolle (→ Task in Control).

Bei Multiprozessoren gibt es CPU-lokale Warteschlangen (siehe auch Abschnitt „Steuern der Tasks über Warteschlangen“ auf Seite 282), die bei der Aktivierung von Tasks zyklisch bestückt werden. Pro CPU wird die in der zugeordneten Warteschlange stehende Task mit der höchsten Initiierungspriorität ausgewählt. Eventuell höhere Prioritäten von Tasks in Warteschlangen, die anderen CPUs zugeordnet sind, spielen keine Rolle. Zusätzlich wird die Strategie „Fremd vor IDLE“ verfolgt, d.h bevor die CPU mangels Last in den Wartezustand übergeht, wird eine Task aus einer „fremden“ Warteschlange initiiert. In diesem Fall erfolgt der Zugriff auf diejenige Warteschlange, die die meisten Tasks enthält („längste Q1“).

Bei Einsatz der Funktion TANGRAM erfolgt die Bestückung der CPU-lokalen Warteschlangen nicht zyklisch, sondern gemäß den TANGRAM-Zuordnungs-Algorithmen (siehe Abschnitt „Einführung in das TANGRAM-Konzept“ auf Seite 254). In diesem Zusammenhang wird die Strategie „IDLE vor Fremd“ verfolgt.

Initiierungspriorität

Die Ermittlung der Initiierungspriorität erfolgt analog der Berechnung der Aktivierungspriorität. Zusätzlich wird berücksichtigt:

- der Zeitpunkt t_A des letzten „System Service Slice Runouts“ (es wird die Differenz: Aktueller Zeitpunkt - t_A gebildet)
- die „Task in Control“ wird bei der Prioritätsberechnung bevorzugt (um die Verdrängungsrate möglichst gering zu halten, gilt: P = P + 5)

Deinitiierung

Im Sinne einer effizienten Nutzung der CPU entzieht das System einer Task die Kontrolle (auch wenn diese Task die höchste Priorität besitzt), wenn Wartezeiten unmittelbar absehbar sind:

- Bei kurzen Wartezeiten erfolgt der Übergang in den Zustand „active, not ready“, z. B. bei Durchführung der Ein-/Ausgabe (DVS-, Paging-Ein-/Ausgabe), Warten auf Börsen- oder ITC-Ereignisse, Warteaufruf VPASS 0 im Programm.
- Bei langen Wartezeiten kommt es zusätzlich zu einer Deaktivierung, z.B. bei Terminal-Eingabe im Dialogbetrieb, Warteaufruf PASS, VPASS im Programm.

Verdrängung

Auf Initiierungsebene erfolgt eine Verdrängung ausschließlich in Abhängigkeit von der Initiierungspriorität.

Damit die „Task in Control“ verdrängt werden kann, muss die Priorität der neu zu initiierenden Task:

- mindestens um den Wert 5 höher sein
- mindestens um den Wert 10 höher sein, wenn sich die „Task in Control“ im Funktionszustand TPR befindet

Nach dem Aufruf eines SVC, der nicht zur Deinitiierung der Task geführt hat, findet keine Verdrängung statt. Nur wenn während der Bearbeitung dieses SVC eine andere Task auf die erste Position der CPU-Warteschlange gelangte und die oben genannten Bedingungen erfüllt sind, verliert die SVC-rufende Task die CPU.

Kontrollfunktion der CPU-Verwaltung

- Micro Time Slice (MTS, Mikro-Zeitscheibe)

  Die „Micro Time Slice“ ist diejenige Zeit, die eine Task maximal die CPU ohne Unterbrechung belegen darf.

  Die verbrauchte CPU-Zeit im Funktionszustand TU und TPR wird aufsummiert, um die CPU-Intensität der einzelnen Task festzustellen. Bei „Micro Time Slice Runout“ erfolgt die Überprüfung bzw. Neufestsetzung der Priorität. Bei Multiprozessoren wird nach einem „Micro Time Slice Runout“ aus allen Warteschlangen (Q1) diejenige Task ausgewählt, die die höchste Priorität hat.

  Die Größe der MTS ist innerhalb zweier Grenzwerte variabel und hängt von der CPU-Intensität ab. Nach jeder mit einem Wartezustand verbundenen Ein-/Ausgabe wird die MTS neu festgesetzt:

  ```
  MTS = Aktuelle CPU-Zeit - CPU-Zeit der vorletzten Ein-/Ausgabe
  ```

  Die Grenzwerte sind abhängig von der CPU-Geschwindigkeit und sind umso kleiner, je schneller die CPU ist.

  Je Ein-/Ausgabe-intensiver die Charakteristik einer Task ist, desto kleiner ist die zugehörige MTS, wobei aber ein Minimum-Wert nicht unterschritten werden kann. Aufgrund der geringen CPU-Intensität einer Ein-/Ausgabe-intensiven Task tritt das Ereignis „Micro Time Slice Runout“ nicht auf.

  Ändert sich die Task-Charakteristik in Richtung größerer CPU-Intensität, so ergibt sich relativ rasch ein „Micro Time Slice Runout“ mit anschließender Prioritätsberechnung. Damit ist ein schnelles Reagieren des Systems (es braucht nicht die periodische Prioritätsüberprüfung abgewartet werden) auf Änderungen der Lastcharakteristik von Ein-/Ausgabe-intensiv in Richtung CPU-intensiv gewährleistet. Dieser Fall der Laständerung ist besonders kritisch, da das Dominieren CPU-intensiver Tasks eine entsprechende Verschlechterung des Simultanarbeitsgrades und damit des Durchsatzes zur Folge hat.

9.4 Steuern der Tasks über Warteschlangen

Im Betriebssystem vorhandene Tasks können sich grundsätzlich in fünf verschiedenen Zuständen befinden.

- TASK IN CONTROL
- ACTIVE READY
- ACTIVE NOT READY
- INACTIVE READY
- INACTIVE NOT READY

Es können nur so viele Tasks den Zustand TASK IN CONTROL einnehmen, wie der Server CPUs hat.

Die übrigen vier Zustände sind Wartezustände, die sich in zwei Gruppen einteilen lassen, je nachdem, ob die Berechtigung zur Hauptspeicher-Nutzung bereits erteilt wurde (ACTIVE) oder nicht (INACTIVE).

Die Zuordnung der Tasks zu den einzelnen Wartezuständen erfolgt mit Hilfe von Warteschlangen (Queues), wobei aus Übersichtlichkeitsgründen bei den Zuständen NOT READY eine weitere Unterteilung nach Ereignissen stattfindet, warum diese Task nicht ablaufbereit ist.

Zur Verbesserung des MP-Faktors bei Multiprozessoren sind die Warteschlangen des Aktivraumes für jede CPU getrennt vorhanden (CPU-lokal), während die restlichen Warteschlangen für alle CPUs gemeinsam sind (siehe Bild 17 auf Seite 283).

Die Zustandswechsel (charakterisiert durch Warteschlangenübergänge) werden durch die PEND/UNPEND-Routinen realisiert:

- UNPEND-Routinen
  bringen die Task aus der jeweiligen Warteposition näher in Richtung Benutzung der CPU.
- PEND-Routinen
  bringen die Task aufgrund eines eintretenden Ereignisses in einen Wartezustand.

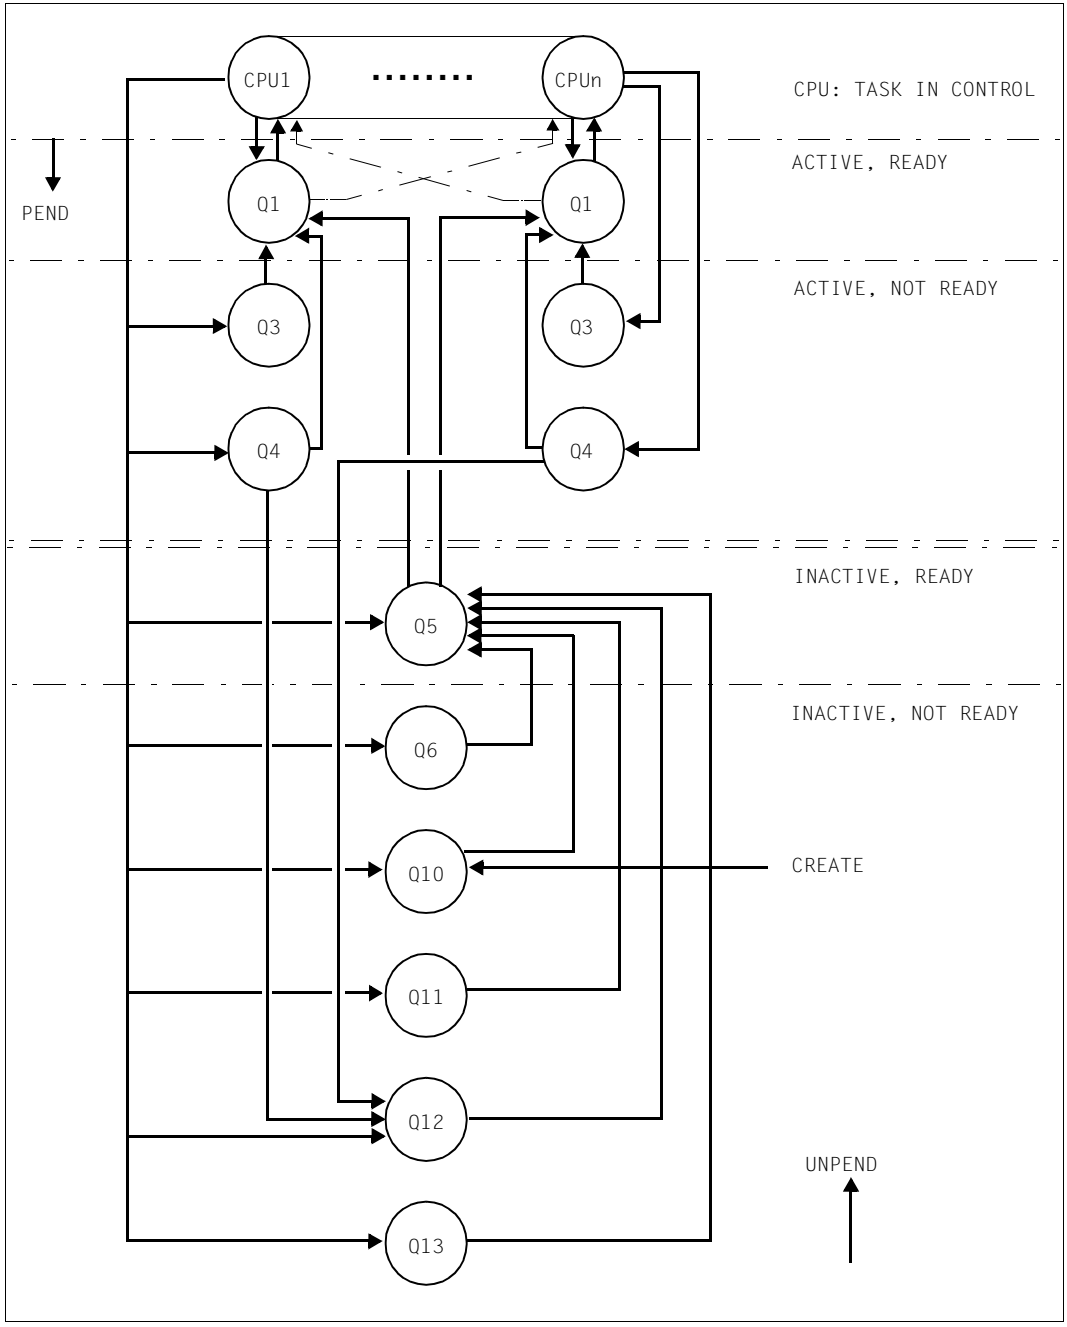

Bild 17: Warteschlangenübergänge

Übersicht über die einzelnen Warteschlangen

Die Warteschlangen Q0, Q1, Q2, Q3 und Q4 sind einmal pro CPU vorhanden.

- TASK IN CONTROL

  Q0 Task belegt CPU

- ACTIVE, READY

  Q1 CPU-Queue
  Sie enthält aktive ablaufbereite Tasks, die auf Benutzung der CPU warten.

- ACTIVE, NOT READY

  Q2 Sonderfall (nicht eingezeichnet):
  Mess-System-Tasks

  Q3 Warten auf Beendigung der Paging-Ein-/Ausgabe

  Q4 Warten auf Beendigung der DVS-Ein-/Ausgabe (Platte, Band)
  Warten auf Börsen-Ereignisse (Short Wait)
  Warten auf Beendigung `VPASS 0`, `VPASS MSEC=Y`

- INACTIVE, READY

  Q5 Memory-Queue
  Sie enthält inaktive ablaufbereite Tasks, die auf Berechtigung zur Hauptspeicher-Nutzung warten.
  Besteht aus 4-16 Sub-Queues entsprechend den vordefinierten Kategorien:

  ```
  SYS
  TP
  DIALOG
  BATCH
  ```

  und bis zu 12 weiteren von der Systembetreuung definierbaren Kategorien.

  Q6 PCS-Not-Admitted-Queue
  Diese Warteschlange enthält inaktive ablaufbereite Tasks, die vom PCS (Performance Control Subsystem) nicht zur Aktivierung zugelassen werden.

- INACTIVE, NOT READY

  Q10 HOLD-Queue
  Enthält neu erzeugte Tasks (Aufruf: `$CREA`)
  Warten auf periphere Geräte (`/SECURE-RESOURCE-ALLOCATION`)
  Anhalten durch Operator (`/HOLD-TASK`)
  Warten auf WHEN-Bedingung (`/WAIT-EVENT UNTIL=*USER-SWITCHES`)
  Nichtbeendbare Tasks (schwere Fehler-Situationen)
  Job-Scheduler-Tasks, die gerade nichts tun

  Q11 Inaktive System-Tasks

  Q12 Warten auf Terminal-Eingabe (`WRTRD`, `RDATA`)
  Warten auf Börsen-Ereignisse (Long Wait)
  Warten auf Beantwortung einer Bedienplatzmeldung

  Q13 Warten auf Beendigung der Aufrufe `PASS`, `VPASS`
  Warten auf ITC-Ereignis

9.5 Ablauf einer Ein-/Ausgabe

Die Abwicklung von Ein-/Ausgaben erfolgt in BS2000/OSD über das Datenverwaltungssystem (DVS). Im Vergleich zu den Befehlsausführungen in der CPU (Mikrosekunden oder Bruchteile davon) dauert die physikalische Durchführung der Ein-/Ausgabe um eine Größenordnung länger (Millisekunden) und hat daher einen maßgeblichen Einfluss auf das Zeitverhalten.

Bei interaktiven Anwendungen stehen die Ein-/Ausgaben auf Platten (genauer: logische Volumes) im Vordergrund. Im folgenden Abschnitt werden die wesentlichen Zeitanteile bei der Abwicklung einer Ein-/Ausgabe näher erläutert.

9.5.1 Ein-/Ausgaben auf Platten

Der Anwender formuliert seine Ein-/Ausgabe-Anforderungen im Anwenderprogramm mit Makroaufrufen (GET, PUT, GETKY, STORE, PAM, ...) auf **logischer** Ebene.
Bei Verwendung höherer Programmiersprachen werden die READ- bzw. WRITE-Anweisungen durch das jeweilige Laufzeitsystem entsprechend umgesetzt.

Die Makro-Auflösung enthält einen äquivalenten SVC-Aufruf, der aber nicht bei jedem Makroaufruf durchlaufen wird.

Bei sequenziellen Eingabe-Operationen (GET) stellt die Zugriffsmethode (SAM, ISAM) dem Anwender den nächsten logischen Satz aus dem Eingabe-Puffer zur Verfügung, in den der Datenblock physikalisch eingelesen wurde. Nur wenn sich kein Satz mehr im Eingabe-Puffer befindet, wird der SVC-Aufruf durchlaufen.

Bei sequenziellen Ausgabe-Operationen (PUT) erfolgt der SVC-Aufruf durch die Zugriffsmethode (SAM, ISAM) nur, wenn im Ausgabe-Puffer kein Platz mehr ist.

Bevor eine „Update“-Operation PUTX (ISAM) durchgeführt werden kann, muss der entsprechende Satz gelesen worden sein (GET, GETKY). Nur wenn sich beim Update-Vorgang die Satzlänge vergrößert, wird der SVC-Aufruf durchlaufen.

Stellt die aufgerufene DVS-Zugriffsmethode fest, dass eine physikalische Ein-/Ausgabe durchzuführen ist, so wird mit dem SVC-Aufruf `$EXCP` (Execute Channel Program) oder `$XCPW` (Execute Channel Program with Wait) die Ein-/Ausgabe angestoßen.
Diese Aufrufe stehen dem Anwender nicht unmittelbar zur Verfügung.

Die zeitlichen Verhältnisse auf der Kanal- bzw. Platten-Seite sind für beide Aufrufe gleich; nur die Reaktion der aufrufenden Programmroutine ist unterschiedlich.

Beim Aufruf `$XCPW` wird der Programmlauf unterbrochen (Versetzung in den Wartezustand durch die systeminterne PEND-Routine von Q0 → Q4) und erst nach Beendigung der Ein-/Ausgabe fortgesetzt.

Die Warteschlange Q4 ist nur das „Sammelbecken“ für Tasks, die auf Durchführung bzw. Beendigung der Ein-/Ausgabe (und Börsen-Ereignisse) warten.
Aus der Länge der Q4 kann i.A. noch kein Rückschluss auf einen evtl. Engpass bei der Ein-/Ausgabe getroffen werden. Wesentlich sind in diesem Zusammenhang die Warteschlangen vor den einzelnen Ein-/Ausgabe-Geräten (Device-Queues; siehe auch Reportgruppe DEVICE von openSM2).

Beim Aufruf `$EXCP` läuft das Programm asynchron zur Abwicklung der Ein-/Ausgabe weiter (führt andere, von der Ein-/Ausgabe unabhängige Funktionen durch) und gibt zu gegebener Zeit einen expliziten Warte-Aufruf. Der Einfachheit halber wird im Folgenden nur der Aufruf `$XCPW` weiter dargestellt.

Ist das logische Volume zum Aufrufzeitpunkt des `$XCPW` belegt (mit der Durchführung von Ein-/Ausgaben für andere Anwender beschäftigt), so tritt eine Wartezeit vor dem Volume auf. Eine höhere Volume-Auslastung bewirkt eine größere Wartezeit (siehe Abschnitt „Software-Bedienzeit“ auf Seite 289).

Bei Einsatz der Funktion PAV stehen pro logischem Volume (Basis-Gerät) mehrere Geräteadressen (Alias-Geräte) zur Verfügung, über die gleichzeitig Ein-/Ausgabe-Aufträge abgewickelt werden können. Die Entstehung größerer Wartezeiten wird dadurch vermieden.

Sobald das Volume frei ist (oder zumindest ein freies Alias-Gerät verfügbar ist), wird vom Betriebssystem der Befehl START SUBCHANNEL (SSCH) zusammen mit dem „Operating Request Block“ (ORB), der in der „Logical Path Mask“ eine Beschreibung der möglichen Zugriffspfade enthält, an das DCS übergeben.

Sind sämtliche Zugriffspfade belegt (was bei mehreren Zugriffspfaden sehr selten vorkommt), tritt eine entsprechende Wartezeit auf (Function pending time: siehe Reportgruppe SERVICETIME von openSM2), bevor die Ein-/Ausgabe mit dem Befehl START IO (SIO) eingeleitet werden kann. Die Wartezeit auf einen freien Zugriffspfad ist i.d.R. so klein, dass sie vernachlässigt werden kann.

Auf SX- und SQ-Servern wird die eigentliche Abwicklung der Ein-/Ausgabe (ausgelöst durch den zu SSCH äquivalenten Befehl) durch die I/O-Treiber von X2000 auf einer separaten CPU durchgeführt.

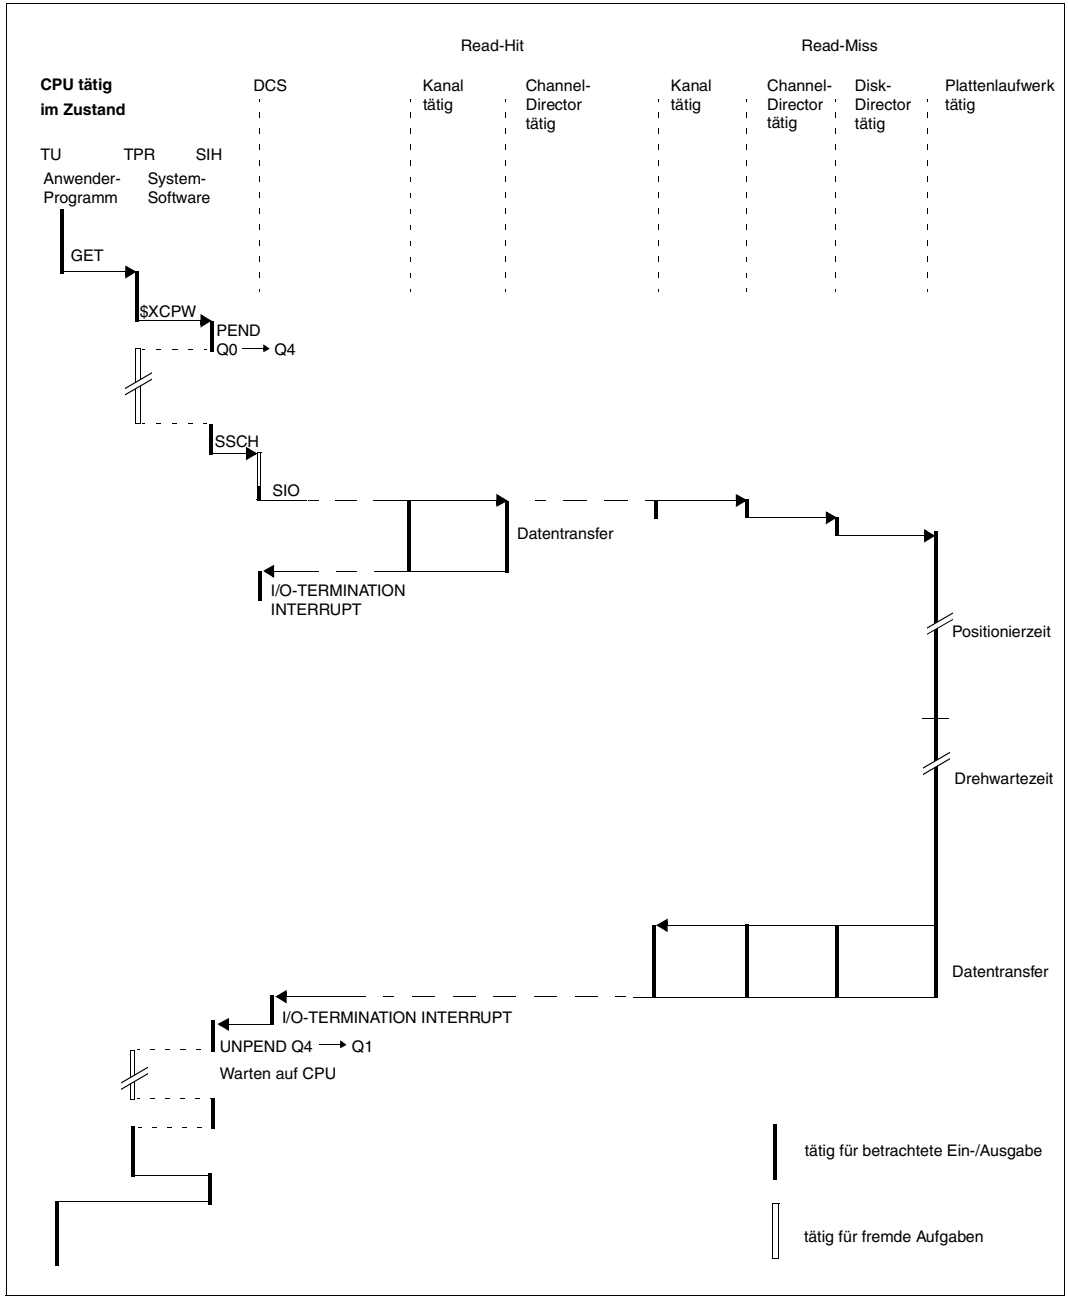

Bild 18: Zeitlicher Ablauf einer Platten-Ein-/Ausgabe
Read-Hit/Read-Miss beim Plattenspeichersystem Symmetrix

9.5.2 Hardware-Bedienzeit

Als Hardware-Bedienzeit wird die Zeit vom Befehl START SUBCHANNEL (SSCH) bis zum IO-Termination-Interrupt bezeichnet.

Beim Plattenspeichersystem Symmetrix ergibt sich eine stark unterschiedliche Hardware-Bedienzeit, je nachdem ob es sich um einen Cache-Hit oder Cache-Miss handelt.

Ein typischer Wert für einen Cache-Hit liegt bei Ein-/Ausgaben mit einer Blockgröße von 4 KB bei ca. 1 ms. Der Wert für einen Cache-Miss liegt in diesem Fall bei ca. 10 ms (siehe Abschnitt „Eigenschaften von Plattenspeichersystemen“ auf Seite 57).

9.5.3 Software-Bedienzeit

Die Software-Bedienzeit je Ein-/Ausgabe, die der Anwender sieht, besteht im Wesentlichen aus:

- der Wartezeit vor dem jeweiligen Volume und
- der Hardware-Bedienzeit bei der Durchführung der physikalischen Ein-/Ausgabe (siehe Reportgruppe DISK von openSM2: SOFTWARE-DURATION und HARDWARE-DURATION).

Die Wartezeit W vor dem Volume ergibt sich nach den Gesetzen über die Warteschlangenbildung in Abhängigkeit von:

- der Verteilung der Zeiten zwischen den Ein-/Ausgabe-Anforderungen (Zwischenankunftszeiten),
- der Verteilung der Hardware-Bedienzeiten und
- der Auslastung des Volumes.

Ohne tieferes Eindringen in die Warteschlangen-Theorie können für die Abschätzung der durchschnittlichen Wartezeit W die zwei folgenden Formeln herangezogen werden:

1. Bei Annahme der Voraussetzung „M/M/1“ (ungünstigster Fall):

   M exponentielle Verteilung der Zwischenankunftszeiten

   M exponentielle Verteilung der Hardware-Bedienzeiten

   1 eine Bedienstation

   $$W = S \bullet \frac{U}{1 - U}$$

   S durchschnittliche Hardware-Bedienzeit (Service time)

   U Auslastung des Volumes (Utilization)

Beispiel

S = 6 ms; U = 30%

$$W = 6\ ms \bullet \frac{0,3}{1-(0,3)} = 2,6\ ms$$

Bei 30% Auslastung des Volumes müssen die Ein-/Ausgabe-Anforderungen durchschnittlich 2,6 ms warten, bis das Volume frei wird.

2. Bei Annahme der Voraussetzung „M/D/1“ (günstigster Fall):

   M exponentielle Verteilung der Zwischenankunftszeiten

   D konstante Hardware-Bedienzeit

   1 1 Bedienstation

$$W = S \bullet \frac{U}{2\ \ (1-U)}$$

Ein Vergleich der beiden Formeln zeigt, dass die durchschnittliche Wartezeit W bei konstanter Hardware-Bedienzeit (M/D/1) nur halb so groß ist wie bei einer Exponentialverteilung der Hardware-Bedienzeit (M/M/1).

In der Praxis kommt weder eine streng exponentielle Verteilung der Hardware-Bedienzeiten, noch eine konstante Bedienzeit vor. Die aufgrund der Auslastung von Volumes auftretenden Wartezeiten liegen etwa in der Mitte der Ergebnisse der beiden Formeln.

Die folgende Tabelle verdeutlicht, um welchen Faktor die Hardware-Bedienzeit abhängig von der Volume-Auslastung gedehnt wird.

Volume-Auslastung (%)	Dehnfaktor	
	M/M/1	M/D/1
10	1,11	1,06
20	1,25	1,13
30	1,43	1,21
40	1,67	1,33
50	2,00	1,50
60	2,50	1,75
70	3,33	2,17
80	5,00	3,00
90	10,00	5,50

Die Wartezeit vor dem Volume bildet einen wesentlichen Bestandteil der Ein-/Ausgabezeit. Volumes, die von mehreren Anwendern gemeinschaftlich benutzt werden, sollten nicht stärker als 30% ausgelastet werden.

Bei Einsatz der Funktion PAV stehen pro logischem Volume (Basis-Gerät) mehrere Geräteadressen (Alias-Geräte) zur Verfügung, wodurch die nach außen sichtbare Volume-Auslastung deutlich absinkt. (SM2 bildet den Mittelwert über das Basis-Gerät und die zugehörigen Alias-Geräte.)

10 Einsatz des Mess-Systems openSM2

Die Produktlinie openSM2 ist ein Softwareprodukt zur Überwachung und Leistungsvermessung von BS2000/OSD-Servern. Es ist zur Beobachtung des Lastverhaltens und der Betriebsmittelauslastung, zur Abschätzung von Trends und zur Problemanalyse sehr gut geeignet. Einführende Informationen zu openSM2 finden Sie im Handbuch „openSM2“ [19].

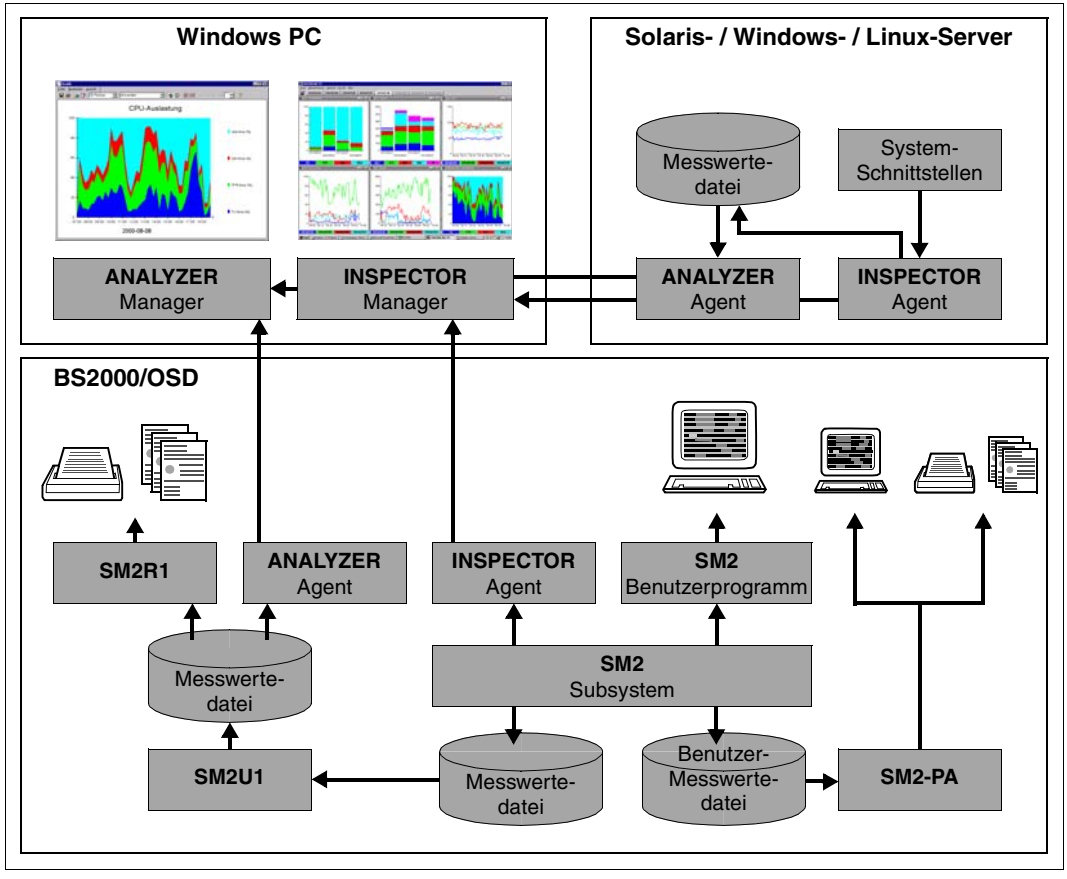

Bild 19: Komponenten der Produktlinie openSM2

10.1 Messmonitor SM2

Die Berechnung der Messwerte durch den Messmonitor SM2 erfolgt in gleichmäßigen zeitlichen Abständen, den Messintervallen (10 Sekunden bis 1 Stunde). Am Ende jedes Messintervalls werden die Messwerte in einen Puffer und in die Messwertedatei geschrieben.

Die Erfassung der Messwerte erfolgt

- einmal am Ende des Messintervalls (für aufsteigende Zähler durch Differenzbildung zu den Werten des vorhergehenden Messintervalls)
- während des ganzen Messintervalls (für variierende Messgrößen)
  - stichprobengesteuert (Sampling)
    durch Erfassung einer Stichprobe mehrmals im Messintervall (Stichprobenintervall) und Bildung des Mittelwerts über alle Stichprobenwerte am Ende des Messintervalls
  - ereignisgesteuert (Eventing)
    durch Aktivierung einer Messroutine beim Eintreten bestimmter Ereignisse, z.B. Start einer Ein-/Ausgabe

Art	Genauigkeit	Overhead	Messzeitraum	Datenvolumen
Sampling	abhängig von der Häufigkeit der Stichproben	abhängig von der Häufigkeit der Stichproben	beliebig lang	überschaubar
Eventing	hoch	abhängig von der Anzahl der Ereignisse	kurz (15-30 Min.)	u.U. umfangreich

Für folgende Anlässe wird der Einsatz von SM2 empfohlen:

- ständig (System-begleitend)
- bei auftretenden Lastproblemen
- bevor eine neue Anwendung auf den Server zu übernehmen ist
- vor und nach Umstellung auf neue Versionen
  (z.B. Betriebssystem, Anwendersoftware, Datenbanken)
- bei Einsatz neuer Funktionen (z.B. NK-ISAM, PCS, DAB)
- bei Änderung der Hardware

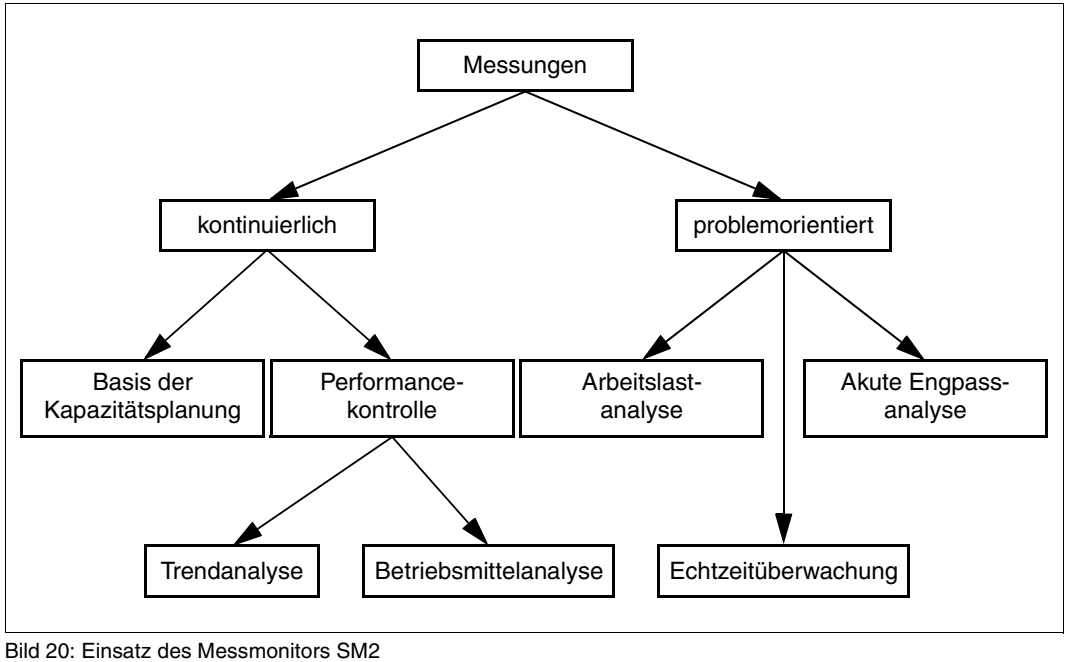

Bild 20: Einsatz des Messmonitors SM2

10.2 Routinemäßige Systemüberwachung

10.2.1 Parameter für die Messung und Auswertung

SM2 sollte in jeder Session mitlaufen und seine Ergebnisse in eine Datei protokollieren. Bei Langzeitmessungen genügt zur Gewährleistung der Vertrauenswürdigkeit der Messdaten (diese ist abhängig von der Zahl der Stichproben) die Entnahme einer Stichprobe pro Sekunde bezogen auf ein Auswerte-Teilintervall von einer Stunde:

Stichprobenintervall (SAMPLING-PERIOD)	1000 Millisekunden
Messintervall (OFFLINE-PERIOD)	5 Minuten
Auswerte-Teilintervall	1 Stunde
Messzeitraum	von System Ready bis Shutdown

Es ist nicht notwendig, jede Session auszuwerten. Um den Überblick zu behalten, muss man aber zumindest häufig Stichproben in Form von Tagesauswertungen machen. Auswertungen über längere Zeiträume sind sehr gut dazu geeignet, Trends aufzuweisen und Entscheidungen über Investitionen besser zu fundieren. Bei Jahresauswertungen sollte man sich auf wenige Reports beschränken.
Bei ungewöhnlichen Ereignissen wie Beschwerden, Anfragen oder Konfigurationsänderungen genügt es nicht, nur den Tag des Interesses auszuwerten. Man benötigt zusätzlich die Auswertung eines anderen Tages zum Vergleich. Legt man die Grafiken beider Auswertungen nebeneinander und vergleicht die Bilder, dann gelangt man anhand der Unterschiede viel schneller zu relevanten Aussagen. Zu beachten ist, dass entsprechende Grafiken in den beiden Auswertungen in verschiedenen Maßstäben gedruckt sein können, was den Vorher-Nachher-Vergleich etwas erschwert.

SM2 wird auch eingesetzt, um Systemmessungen zu unterstützen. Deshalb liefert SM2 einige Reports, die über das Interesse an Routineüberwachungen des Systems nach Standard-Gesichtspunkten hinausgehen.

10.2.2 Bewertung charakteristischer Reports

Für Routine-Überwachungen haben sich folgende Reports des Auswerteprogramms ANALYZER als besonders aussagekräftig erwiesen:

Reportgruppe	Report	Bedeutung
CATEGORY-CPU	CPU utilization (TU + TPR) for category	CPU-Auslastung pro Kategorie [1]
CATEGORY-IO	IOs for category	DVS-Ein-/Ausgaberaten pro Kategorie [1]
	Duration of non paging IOs for category	HW-/SW-Bedienzeit pro Kategorie [1]
CATEGORY-QUEUE	Active and inactive task for category	Anzahl Tasks pro Kategorie
CHANNEL	Utilization	Kanalauslastung [2]
CPU	Utilization real	CPU-Auslastung (echter Wert; auch bei VM2000)
	Sum SVC calls	SVC-Aufrufe
DISK	Utilization	Plattenauslastung (logische Volumes)
IO	IOs for device classes	DVS-Ein-/Ausgaberaten
	Paging IOs	Paging-Ein-/Ausgaberaten
MEMORY	Paging area utilization	Auslastung Pagingarea
	Page frames	Größe des System-Working-Set
PERIODIC-TASK-JOBNAME		Verbrauchsdaten pro Jobname:
	CPU time	CPU-Anteil
	IO	Ein-/Ausgaberaten
PERIODIC-TASK-TSN		Verbrauchsdaten pro TSN:
	CPU time	CPU-Anteil
	IO	Ein-/Ausgaberaten
PERIODIC-TASK-USERID		Verbrauchsdaten pro Benutzerkennung:
	CPU time	CPU-Anteil
	IO	Ein-/Ausgaberaten
VM2000	VM2000 utilization	Lastanteile der VM2000-Gastsysteme [3]
	VM2000 Hypervisor	VM2000-Hypervisor-Anteil [3]
WORKING-SET	Main memory utilization	verfügbare Hauptspeicherseiten

[1] mit eingeschaltetem Messprogramm SYSTEM

[2] bei Kanal Typ FC nur mit eingeschaltetem Messprogramm CHANNEL-IO

[3] mit Messprogramm VM2000 (alle geplanten und gemessenen Gastsystemanteile liegen im Monitorsystem)

10.2.3 Anmerkung zu verschiedenen Reports

Reports der Reportgruppe BCAM-CONNECTION

Diese Reports liefern dann sinnvolle Ergebnisse, wenn es um den Anteil der Antwortzeiten geht, der im Server verursacht wird. Die Übertragungszeiten der Nachrichten und ggf. Staus im Netz werden nicht erfasst. Daher sind diese Reports nur dazu geeignet, die Lastsituation im Zentralrechner zu beobachten. Aussagen über die vom Anwender erlebten Antwortzeiten (siehe Kapitel „Leistungserwartungen aus Anwendersicht“ auf Seite 17) sind nicht möglich.

Report „CPU utilization (TU+TPR) for category“ der Reportgruppe CATEGORY-CPU

Dieser Report und der nachfolgend beschriebene Report der Reportgruppe CATEGORY-IO sind nur bei Einschaltung des SM2-Messprogramms SYSTEM zu erhalten. Der Report dient dazu, die Verursacher-Kategorie für eine zu hohe CPU-Auslastung zu finden oder die Aufteilung der CPU auf die verschiedenen Kategorien zu überwachen. Letzteres ist ein Hilfsmittel zur Einstellung von PRIOR bzw. PCS.

Report „IOs for category“ der Reportgruppe CATEGORY-IO

Dieser Report dient der Überwachung der Anzahl der Ein-/Ausgaben für die Kategorien. Zur Systemsteuerung ist er kaum einzusetzen, da die Anzahl der Ein-/Ausgaben der Kategorie bei der Steuerung der Kategorien nicht berücksichtigt wird. Er ist also der Einstieg für die Lösung eines Leistungsproblems. Für eine tiefergehende Engpass-Analyse kann der Betriebsmittelbedarf (CPU-Zeit, Anzahl Ein-/Ausgaben) mit dem Messprogramm TASK bis auf Taskebene verfolgt werden.

Report „Utilization“ der Reportgruppe CHANNEL

Bei Kanälen mit angeschlossener Plattenperipherie sollte eine Auslastung von 60% nicht überschritten werden.

Beim Kanal Typ FC muss zur Erfassung der Auslastung das Messprogramm CHANNEL-IO eingeschaltet sein. Die Auslastung kann beim Kanal Typ FC nicht direkt gemessen werden, sondern wird indirekt bestimmt, indem die aktuelle Anzahl Ein-/Ausgabe-Operationen unter Berücksichtigung der Blockgröße mit einem Durchsatzwert verglichen wird, der bei Labormessungen maximal erreicht werden konnte.

Kanalauslastung bei VM2000-Betrieb:

- Kanal Typ S: Da nur die gesamte Auslastung eines Kanal gemessen werden kann, ist es nicht möglich die Auslastungsanteile der einzelnen Gastsysteme zu ermitteln. In jedem Gastsystem wird also immer die Gesamtauslastung eines Kanals durch alle Gastsysteme ausgegeben.

- Kanal Typ FC: Nur bei eingeschaltetem Messprogramm CHANNEL-IO wird die Auslastung ermittelt und zwar über die gastsystem-spezifische Ein-/Ausgaberate. Die Ausgabe der Auslastung erfolgt daher gastsystem-bezogen. Der Summenwert über alle Gastsysteme sollte 60% nicht übersteigen.

Kanäle für Magnetbandkassetten dürfen bis 100% belastet werden.

Zu hohe Kanalbelastungen können anzeigen, dass zuviele Geräte an einem Kanal hängen. Aber auch die Verwendung der Seitenkettung treibt die Kanalbelastung hoch. Deshalb sollte diese Funktion nur benutzt werden, wenn sie erkennbare Vorteile bringt. Das ist immer dann der Fall, wenn alle mit einer Ein-/Ausgabe übertragenen Blöcke benötigt werden und damit weitere Ein-/Ausgaben eingespart werden.

Reports der Reportgruppe CPU

Im Report „Utilization real“ wird die gemessene CPU-Auslastung wiedergegeben (auch bei VM2000-Betrieb). Der Report „Utilization normed“ sollte nicht verwendet werden, insbesondere nicht bei VM2000-Betrieb!

Die CPU-Auslastung ist je nach Anwendungsart und Lastart unterschiedlich zu beurteilen. Bei reinen Batch-Anwendungen ist eine Auslastung von 100% machbar und wünschenswert. Eine ausgewogene Auslastung der übrigen Betriebsmittel soll angestrebt werden.

Bei Mischlastbetrieb mit TP-, Dialog- und Batch-Anwendungen sollte die Hauptanwendung maximal 70% der CPU-Leistung des Servers aufnehmen (bei Multiprozessor-Servern sind, abhängig von der Anzahl CPUs, bis zu 90% für die Hauptanwendung vertretbar). Die ideale Hintergrundlast macht keine Ein-/Ausgaben und kein Paging. Sie ist extrem rechenintensiv und dadurch ein guter Verbraucher für Restkapazitäten. Solche Eigenschaften gestatten eine vollständige Nutzung der CPU, sind jedoch in der Praxis selten anzutreffen. Jede Ein-/Ausgabe und jeder Paging Transfer können die TP- oder Dialog-Anwendungen stören. Ein-/Ausgabe-intensive Lasten und Programme mit großem Speicherbedarf sollten nicht als Hintergrundlast zugeladen werden. Die Hintergrundlast muss über Prioritäten bzw. PCS-Einstellungen gegenüber der Hauptanwendung deutlich zurückgesetzt werden. Ihre Dateien sollten idealerweise auf anderen Plattenlaufwerken (zumindest aber auf anderen Volumes) liegen und über andere Pfade erreichbar sein.

Der SIH-Anteil hängt u.a. ab von der Anzahl der Ein-/Ausgaben jeder Art und der Intensität der Task-Kommunikation. Der SIH-Anteil sollte 20% (S-Server) bzw. 10% (SX- und SQ-Server) nicht überschreiten. Hohe TPR-Anteile sind durch SVC-Aufrufe bedingt, die aufwendige Systemdienste ausführen. Die Last kann als normal angesehen werden, wenn gilt:

`TU + TPR > 3 * SIH` (S-Server) bzw. `TU + TPR > 7 * SIH` (SX- und SQ-Server)

Es gibt immer wieder Einzelfälle, in denen die Last die o.g. Regeln verletzt und trotzdem ein zufriedenstellendes Verhalten hat. Solange die Antwortzeiten gut sind, besteht in solchen Fällen kein Grund zum Eingreifen.

In der Regel laufen die Anwendungen auf einem SX- oder SQ-Server im /390-Modus. Da Programme, die in diesem Modus laufen, einen höheren CPU-Bedarf als auf S-Servern haben, ist ein hoher Anteil im Funktionszustand TU normal (etwa 60 %, normiert auf 100 % Auslastung). Wird ein höherer normierter TU-Anteil ausgewiesen, so liegt die Leistung des SX- oder SQ-Servers unter dem Nominalwert (dem offiziellen RPF-Wert). Wenn der (normierte) TU-Anteil aber kleiner ist, dann liegt die Leistung über dem Nominalwert.

Report „Time“ der Reportgruppe DISK

Der Report „Time“ ist nur verfügbar, wenn das Messprogramm SAMPLING-DEVICE mit Erfassung von Hardware- und Software-Bedienzeiten eingeschaltet ist. Aus diesem Report kann in Verbindung mit dem Report „Utilization“ ermittelt werden, ob die Plattenperipherie stark belastet ist. Treten Software-Bedienzeiten (Software time) auf, die um mehr als 10% über der Hardware-Bedienzeiten (Hardware time) liegen, dann müssen gelegentlich Ein-/Ausgaben vor einem belegten Volume warten.
Mit dem SM2-Messprogramm DISK-FILE und dem SM2-Online-Report DISK-FILE können dann die betroffenen Dateien ermittelt werden.

Wenn die Anwendung mit asynchronen Ein-/Ausgaben arbeitet, so kann es vermehrt zu langen Software-Wartezeiten kommen ohne dass eine Tuning-Maßnahme nötig bzw. möglich ist.

Report „IOs for device classes“ der Reportgruppe IO

Dieser Report ist im Zusammenhang mit dem Report „Utilization real“ der Reportgruppe CPU zu beurteilen. Es gibt Lasten mit hoher Anzahl von Ein-/Ausgaben und sehr rechenintensive Lasten. Das wichtigste Kriterium ist daher, dass Kanäle und Volumes nicht überlastet sind. Die Richtwerte für die max. Anzahl DVS-Ein-/Ausgaben pro Sekunde sind nach der Regel ermittelt, dass (je nach Servergeschwindigkeit) nur ein Anteil von 15 - 25% (S-Server) bzw. 8 - 12% (SX- und SQ-Server) der CPU-Leistung im Funktionszustand SIH+TPR für die Behandlung der Ein-/Ausgaben verbraucht werden sollte. Es gibt Situationen, in denen diese Grenze sinnvoll überschritten werden kann.

Siehe auch Abschnitt „Richtwerte für die BS2000/OSD-Server“ auf Seite 353.

Report „Paging IOs“ der Reportgruppe IO

Paging erlaubt die effiziente Nutzung eines relativ kleinen Hauptspeichers im Verhältnis zu den virtuellen Adressraumanforderungen.

Durch die verfügbaren kostengünstigen Hauptspeicher wird der Hauptspeicher-Ausbau i.d.R. so groß gewählt, dass dynamisches Paging kein Problem darstellt. Der folgende Text ist daher nur in Sonderfällen zu beachten.

Paging ist die Folge von Speichermangel. Paging erzeugt Last auf der Peripherie und auf dem Prozessor. Deshalb sollten die im Abschnitt „Richtwerte für die BS2000/OSD-Server“ auf Seite 353 angeführten Paging-Raten (Page-Reads pro Sekunde) nicht überschritten werden. Eine Überschreitung der empfohlenen Maximalwerte ist nur zulässig, wenn die Antwortzeiten gut sind **und** alle übrigen Auslastungen (CPU, Kanäle, Volumes) niedrig liegen.

Bei Engpässen am Kanal oder den Paging-Volumes kann es sein, dass die genannten Paging-Raten nicht erreicht werden und dennoch die Antwortzeiten unbefriedigend sind. Verursacht wird dies durch zu lange Wartezeiten bei PAGE READ. Eine Fehlkonfiguration der Paging-Peripherie hat schwere Auswirkungen und muss unbedingt vermieden werden. Sie ist leicht an den Reports „Utilization“ der Reportgruppen CHANNEL und DISK zu erkennen.

TP-Betrieb ist sehr empfindlich gegenüber Paging – dies umso mehr, je mehr wichtige Arbeiten von wenigen zentralen Tasks gemacht werden. Solche Drehscheiben dürfen keine Paging-Ein-/Ausgaben erleiden, da sich die dadurch entstehende Verzögerung auf viele andere Tasks überträgt. Paging neigt dazu, sich schlagartig zu verstärken. Es ist deshalb nicht empfehlenswert, den Hauptspeicher eines Servers voll auszureizen
(siehe auch die Anmerkungen zum Report „Main memory utilization“ der Reportgruppe WORKING-SET sowie die Abschnitte „Überwachen der Hauptspeichernutzung“ auf Seite 35 und „Paging-Aktivitäten“ auf Seite 319).

Report „Paging area utilization“ der Reportgruppe MEMORY

Der maximale Füllstand der Paging Area sollte 50% betragen.

Wenn der mittlere Füllstand des Seitenwechselbereichs nicht größer als 50% ist, dann können Paging-Spitzenlasten mit akzeptablen Paging-Ein/Ausgabezeiten abgefangen werden. Es stehen dann genügend große zusammenhängende Bereiche für das performante Auslagern von geänderten Speicherseiten zur Verfügung.

Spätestens ab einem mittleren Füllgrad von 70% tritt bei Paging-Spitzenlasten eine erhebliche Antwortzeit-Verlängerung ein.

Report „Page frames“ der Reportgruppe MEMORY und „Main memory utilization“ der Reportgruppe WORKING-SET

Der Wert „Available pages (NPP)“ gibt an, wieviel vom realen Hauptspeicher-Ausbau für den Seitenwechsel noch zur Verfügung steht

Seitenwechselvorgänge beginnen aufzutreten, wenn der Wert „Number of page frames for system global wset“ (SWS) etwa 80 - 90% von NPP erreicht.

Steigt der Wert von SWS auf Werte größer 90% von NPP, so sollte an eine Hochrüstung des Hauptspeichers gedacht werden. Bei VM2000-Betrieb reicht hier oft (zumindest als Übergangsregelung) den Hauptspeicher zwischen den Gastsystemen besser aufzuteilen. Bei diesen hohen SWS-Werten wird davor gewarnt neue Anwendungen aufzunehmen oder Versionswechsel häufig verwendeter Software vorzunehmen. Es droht sonst die Gefahr einer deutlichen Steigerung der Paging-Rate!

Reports der Reportgruppen PERIODIC-TASK-...

Diese Reports sind sehr nützlich für die Analyse möglicher Verursacher von Ressourcen-Engpässen (insbesondere CPU und IO). Je nach Anwendung ist es sinnvoller die Analyse auf Basis der Benutzerkennung, des Job-Namens oder der TSN vorzunehmen.

Reports der Reportgruppe VM2000

Aus Messungen auf dem Monitorsystem kann man mit dem Report „VM2000 utilization“ die CPU-Auslastung aller Gastsysteme auswerten. Addiert man dann den Wert aus dem Report „VM2000 hypervisor“ dazu, so ergibt sich die Gesamtauslastung des Servers.

Unter VM2000 kann (je nach Anzahl und Last der Gastsysteme) die BS2000-CPU um 5-15% höher ausgelastet werden als im Native-Betrieb.

10.3 Durchführung einer Engpass-Analyse

10.3.1 Prinzipielle Vorgehensweise

Vor dem Einstieg in die Einzelheiten der Durchführung soll zunächst nochmals auf die grundlegende Problematik bezüglich der Erfüllung der Leistungserwartungen hingewiesen werden:

Leistungserwartungen des einzelnen Anwenders

Die Leistungserwartungen des einzelnen Anwenders sind zeitlicher Natur (Antwortzeit, Verweilzeit). Die Zeitdauer für die Bearbeitung seiner Anforderungen an das IT-System wirkt sich direkt auf den Arbeitsfortgang und damit auf die „Produktivität“ des Anwenders aus.

Die Bearbeitungszeitdauer setzt sich aus der Bedienzeit und der Wartezeit auf die entsprechenden Betriebsmittel zusammen. Während die Bedienzeit den unmittelbaren Betriebsmittelbedarf widerspiegelt, hängt die Wartezeit von der Auslastung der Betriebsmittel ab. Die Leistungserwartungen des Anwenders lassen sich daher umso leichter erfüllen, je geringer die Auslastung der Betriebsmittel ist.

Leistungserwartungen des Server-Betreibers

Die Leistungserwartungen des Server-Betreibers sind aus wirtschaftlichen Gründen auf die Erzielung eines maximalen „Systemdurchsatzes“ (hohe Transaktions- bzw. Job-Durchsatzrate) ausgerichtet, worunter sich implizit die Forderung nach höchstmöglicher Auslastung der Betriebsmittel verbirgt.

Zur Erfüllung der Leistungserwartungen sowohl des einzelnen Anwenders als auch der Systembetreuung ist also immer ein Kompromiss erforderlich.

Trotz der verständlichen Forderung der Investitionsplaner nach höchstmöglicher Auslastung der Betriebsmittel haben sich in der Praxis verschiedene Richtwerte für die Auslastung der Betriebsmittel herauskristallisiert, die nach Möglichkeit nicht überschritten werden sollten.
Diese Richtwerte sind in den meisten Fällen keine technischen Grenzwerte. Ihre Überschreitung führt zu einer ineffizienten Nutzung des IT-Systems und erschwert die Erfüllung der Leistungserwartungen der einzelnen Anwender.

Maßgebend für die Vorgehensweise ist daher vor jeder Messung die Klärung, welche Leistungserwartungen nicht erfüllt werden:

- Systemorientierte Leistungserwartungen (der Systemdurchsatz lässt zu wünschen übrig → die Leistung des **gesamten IT-Systems** ist unbefriedigend)

  Kennzeichen dafür sind:

  – zu niedrige Transaktionsraten (als unmittelbares Ergebnis eines generell unbefriedigenden Antwortzeitverhaltens)
  – zu niedrige Durchsatzraten (allgemein zu lange Verweilzeiten der Aufträge)

- Anwenderorientierte Leistungserwartungen (die Leistungserwartungen **einzelner Anwender** werden nicht erfüllt)

  Kennzeichen dafür sind:

  – zu hohe Antwortzeiten für bestimmte Typen von Transaktionen
  – zu lange Verweilzeiten für bestimmte Aufträge

Liegt ein **systemorientiertes** Leistungsproblem vor, so sind die Ursachen dafür mit größter Wahrscheinlichkeit in der Überlastung eines oder mehrerer Betriebsmittel zu finden.

Beim Auftreten eines **anwenderorientierten** Leistungsproblems gilt es, die Gründe für zeitliche Verzögerungen bei der Behandlung spezieller Lastanforderungen herauszufinden.

Da der Einsatz zusätzlicher Messprogramme zu einem Ressourcen-Mehrbedarf führt (i.W. CPU-Zeit) sollte darauf geachtet werden, dass die Messprogramme nach erfolgreicher Messung wieder abgeschaltet bzw. aus den Start-Prozeduren entfernt werden.

10.3.1.1 Parameter für die Messung und Auswertung

Engpass-Analyse-Messungen werden i.A. zur Zeit der Spitzenbelastung durchgeführt. Zur Erleichterung der Analyse wird die Erfassung möglichst vieler Messdaten angestrebt. Der Messzeitraum sollte eine halbe Stunde bis maximal 1 Stunde betragen.

Als Bezugsgrundlage für die Beurteilung der Messwerte ist ein Zeitraum von 15 Minuten zugrunde zu legen (Mittelwert über 3 Messwerte-Teilintervalle von 5 Minuten).

Die Messdatenerfassung durch SM2 erfolgt teils ereignisbezogen, teils im Stichprobenverfahren. Um die Vertrauenswürdigkeit der Stichproben sicherzustellen, ist eine gewisse Anzahl Messwerte pro Auswerte-Teilintervall erforderlich (mindestens 1500). Es wird ein Stichprobenintervall von 400 Millisekunden empfohlen.

Pro Messintervall erfolgt durch SM2 die Mittelwertbildung über die erfassten Messwerte. Um die Schwankungsbreiten pro Auswerte-Teilintervall transparent zu machen, ist es günstig, dass sich jedes Auswerte-Teilintervall aus mehreren Messintervallen zusammensetzt.

Empfohlene Messparameter

Stichprobenintervall (SAMPLING-PERIOD)	400 Millisekunden
Messintervall (OFFLINE-PERIOD)	60 Sekunden
Auswerte-Teilintervall	5 Minuten
Messzeitraum	0,5 - 1 Stunde

Bei Engpass-Analyse-Messungen steht die **Ausgabe der Messwerte in die Messwertedatei** gegenüber der Ausgabe auf Bildschirm im Vordergrund. Es wird also die Datei-Auswertung mit ANALYZER der Online-Auswertung mit INSPECTOR vorgezogen.

10.3.1.2 Messwerte für die Untersuchung von systemorientierten Leistungsproblemen

Für das Auffinden der überlasteten Betriebsmittel sind folgende Daten erforderlich:

- Auslastungswerte: CPU, Kanäle, Geräte (Platten), Hauptspeicher
  Bei Platten sieht SM2 ausschließlich logische Volumes. Ist das Softwareprodukt SHC-OSD im Einsatz, liefert das Messprogramm STORAGE-SYSTEM zusätzlich Daten über die physikalischen Laufwerke von Symmetrix-Systemen.
- Anzahl Ein-/Ausgaben pro Gerät
- Anzahl Tasks pro Geräte-Warteschlange
- Working-Set-Bedarf pro Task-Kategorie

Um die Abhängigkeit des Antwortzeitverhaltens von der Betriebsmittelauslastung zu verdeutlichen, ist die parallele Führung folgender Statistiken günstig:

- verbindungsspezifische Antwortzeit-Statistik (Messprogramm BCAM-CONNECTION)

Zusätzlich wird die Einschaltung folgender Messprogramme empfohlen:

- erweiterte System-Statistik (Messprogramm SYSTEM)
  Dieses Messprogramm liefert kategoriespezifisch u.a. Dehnungen, Verweilzeiten in System-Warteschlangen, Aussagen zur Hardware- und zur Software-Bedienzeit (HARDWARE und SOFTWARE DURATION) von DVS- und Paging-Ein-/Ausgaben.
- erweiterte Geräte-Statistik (Messprogramm SAMPLING-DEVICE)
  Das Messprogramm wird beim Aufruf von SM2 automatisch gestartet, jedoch ohne die Erfassung von Hardware- und Software-Bedienzeit pro Volume. Sollen diese Messwerte ebenfalls in die Messung einfließen, muss das Messprogramm mit den Anweisungen `//SET-SAMPLING-DEVICE-PARAMETER DISK-SERVICETIME=*ON` und `//CHANGE-MEASUREMENT-PROGRAM TYPE=*SAMPLING-DEVICE` neu gestartet werden.
- Kanal-Statistik (Messprogramm CHANNEL-IO)
  Mit diesem Messprogramm erhält man die Anzahl Ein-/Ausgaben sowie die Anzahl übertragener PAM-Blöcke pro Kanal.
- Katalog-Statistik (Messprogramm CMS)
  Dieses Messprogramm gibt Aufschluss über die Anzahl, Art und Zeitdauer der Zugriffe auf Katalogeinträge pro Pubset.
- VM2000-Statistik (Messprogramm VM)
  Dieses Messprogramm sollte bei VM2000-Betrieb nur im Monitor-System gestartet werden (dort aber standardmäßig). Es liefert im Monitorsystem den CPU-Anteil aller Gastsysteme sowie den Anteil an Hypervisor-Active und -Idle.

10.3.1.3 Messwerte für die Untersuchung von anwenderorientierten Leistungsproblemen

Für die Aufdeckung von zeitlichen Verzögerungen sind neben den oben erwähnten globalen Systemauslastungswerten zusätzliche Daten notwendig. Als Einstieg kann mit der periodischen Task-Statistik (Messprogramm PERIODIC-TASK) die entsprechende Task-Auswahl vorgenommen werden.
Für die weitere Analyse sind folgende Messgrößen erforderlich:

- taskspezifische Ermittlung des Betriebsmittelverbrauchs (Messprogramm TASK)
  Das Messprogramm liefert:
  – CPU-Zeitbedarf
  – Anzahl SVC-Aufrufe
  – Anzahl Ein-/Ausgaben und Ein-/Ausgabezeiten, aufgeschlüsselt auf die im Messprogramm definierten Volumes
  – Dauer der Wartezustände
  – Paging-Aktivitäten
  – Nachrichtenlängen pro Terminal-Ein-/Ausgaben

  Für die weitergehende Analyse des CPU-Zeitbedarfs einzelner Tasks in Form einer PC-Statistik und SVC-Statistik wird eine zusätzliche Benutzer-Task-Messung mit anschließender Auswertung durch SM2-PA (Programm-Analysator) empfohlen.
- SVC-Statistik (Messprogramm SVC)
  Das Messprogramm zeigt die Aufrufhäufigkeit jedes SVC getrennt nach TU und TPR.
- DAB-Trefferrate (Messprogramm DAB)
  Das Messprogramm liefert die Anzahl der Zugriffe pro spezifiziertem DAB-Teilbereich.
- Wartezeiten vor einzelnen Geräten (Messprogramm SERVICETIME)
- ISAM-Pool-Trefferrate (bei Einsatz von NK-ISAM; Messprogramm ISAM)
  Das Messprogramm liefert die Anzahl der Zugriffe pro spezifiziertem ISAM-Pool.
- Anzahl Zugriffe auf bestimmte Dateien (Messprogramm FILE)
- UTM-Statistik (Messprogramm UTM)
  Das Messprogramm liefert applikationsspezifische Daten, u.a. Verweilzeit in UTM, Aufteilung der Verweilzeit auf Datenbankanteil, TAC-Klassen-Wartezeit und Zeit für verteilte Verarbeitung. Zusätzlich werden durchschnittliche Verbrauchswerte für CPU und Ein-/Ausgaben in UTM und im DB-System (nur SESAM/SQL und UDS) sowie die Anzahl der DB-Calls pro Dialogschritt bzw. Asynchronvorgang geliefert.

Unter den folgenden Voraussetzungen werden UTM-Messwerte ausgegeben:

- Das Subsystem UTM-SM2 muss gestartet sein.
- Der Start von UTM-SM2 erfolgt automatisch, wenn beim KDCDEF-Lauf der Operand `MAX SM2=ON` angegeben ist.
  Nachträglich wird UTM-SM2 über die UTM-Administrationsschnittstelle mit `KDCAPPL` und `SM2=ON` gestartet, zusammen mit der Bereitschaft zur Messwertübergabe.
- Das SM2-Messprogramm UTM muss eingeschaltet sein.
- Die UTM-Applikation muss bereit sein, Daten an SM2 zu liefern.
  Beim KDCDEF-Lauf, Operand `MAX SM2=ON/OFF/NO`, kann die Messwertübergabe wie folgt beeinflusst werden:
  - Bei `SM2=OFF` (Standardeinstellung) kann über die UTM-Administrationsschnittstelle mit `KDCAPPL` und `SM2=ON` die Messwertübergabe pro Applikation nachträglich eingeschaltet werden.
  - Bei `SM2=ON` ist keine zusätzliche Administration erforderlich.
  - Bei `SM2=NO` wird die Messwertübergabe generell verhindert und kann auch nachträglich nicht eingeschaltet werden.
- DB-spezifische Verbrauchswerte (Ein-/Ausgaben, CPU-Zeit) werden nur unter folgenden Bedingungen geliefert:
  - Das BS2000-Accounting ist aktiv.
  - Der UTM-Abrechnungssatz UTMA ist eingeschaltet
    (mit `/MODIFY-ACCOUNTING-PARAMETERS, ADD-RECORD-TYPE=UTMA`).
  - Das UTM-Accounting ist eingeschaltet (`KDCAPPL`, Parameter `ACC=ON`).
  - Bei SESAM/SQL wird zusätzlich mit der Anweisung `ACC,TP=ON,CPU` die Messwert-Erfassung aktiviert.

Weitere Informationen sind im Handbuch „openUTM – Konzepte und Funktionen“ [20] und im Handbuch „Einsatz von openUTM-Anwendungen unter BS2000/OSD“ [23] zu finden.

- SYMMETRIX-Statistik (Messprogramm STORAGE-SYSTEM)
  Ist das Softwareprodukt SHC-OSD vorhanden, werden die Hit-Raten von Symmetrix-Systemen erfasst, die entweder über Kanal Typ FC oder Typ S angeschlossen sind. Zusätzlich zu den Daten über logische Volumes, werden auch Informationen über die physikalischen Laufwerke geliefert.
- Information über TCP/IP-Verbindungen (Messprogramm TCP-IP)
  Pro Verbindung wird die IP- und PORT-Nummer samt Anzahl übertragener „Transport Servie Data Units“ geliefert.
- Anzahl Zugriffe und übertragene Daten von Netzgeräten
  (Messprogramm SAMPLING-DEVICE)

- Kommunikation im Rechnerverbund (Messprogramm MSCF)
  Es werden Daten über die Kommunikation des lokalen Rechners mit anderen Rechnern geliefert.
- Daten zu Basisfunktionen im HIPLEX-Verbund (Messprogramm NSM)
- Statistik über Lockanforderungen aus TU, TPR und NSM
  (Messprogramm DLM)
- POSIX-Statistik (Messprogramm POSIX)
  Es werden Messwerte über die Nutzung verschiedener POSIX-Funktionen geliefert.
- Anzahl Zugriffe zum Globalspeicher (Messprogramm GS)
  Es werden Lese- und Schreibzugriffe pro GS-Partition angezeigt.
- detaillierte Platten-Statistik (Messprogramm DISK)
  Dieses Messprogramm verliert mit dem fast ausschließlichen Einsatz von Plattenspeichersystemen mit Cache seine ursprüngliche Bedeutung. Ursache ist die Entkopplung des logischen Volumes vom physikalischen Gerät (siehe Abschnitt „Konfigurierung in BS2000/OSD“ auf Seite 66).

10.3.1.4 Auswertung einer SM2-Messung

Bei der Auswertung mit ANALYZER (bzw. mit SM2R1) empfiehlt sich ein schrittweises Vorgehen:

1. Grobauswertung

   Engpass-Suche durch zeitliche Eingrenzung (Auswerte-Teilintervall = 15 min.)

   Auffinden jener Auswerte-Teilintervalle, in denen die empfohlenen Richtwerte überschritten werden.
   Eine wertvolle Hilfe für das Aufspüren von Engpässen stellt die im ANALYZER (bzw. in SM2R1) vorhandene **automatische Leistungsanalyse** dar. Diese Funktion vergleicht die in der SM2-Datei gesammelten Messwerte mit den im folgenden Abschnitt empfohlenen Richtwerten und gibt eine entsprechende Meldung an den Anwender aus.
   Wichtig ist, dass ausschließlich kritische Zeiträume des Produktivbetriebes für die automatische Leistungsanalyse herangezogen werden.

2. Feinauswertung

   Untersuchen der kritischen Auswerte-Teilintervalle (15 min) durch Herabsetzen des Auswerte-Teilintervalls (TIME-STEPS) auf die Größe des Messintervalls (OFFLINE-PERIOD), um die Schwankungsbreite der Messwerte zu verdeutlichen.

Zur leichteren Beurteilung der Messergebnisse sollte darauf geachtet werden, dass sowohl die Messwerte über Zeitperioden vorliegen, in denen die Leistungserwartungen nicht erfüllt werden, als auch über Zeiträume, in denen die Leistungserwartungen erfüllt werden. Durch den Vergleich beider Fälle wird die Zuordnung der Probleme zu den Ursachen wesentlich erleichtert.

Im folgenden Abschnitt wird versucht, durch die Angabe von Richtwerten für die Auslastung von Betriebsmitteln die Interpretation von Messwerten zu erleichtern.

10.3.2 Untersuchen eines systemorientierten Leistungsproblems

Zum besseren Verständnis der angegebenen Richtwerte für die Betriebsmittelauslastung soll zunächst eine Quantifizierung der Arbeit von BS2000/OSD vorgenommen werden.

Systemzeit (SIH-Zeit) wird i.W. für die Bearbeitung folgender Ereignisse benötigt:

- Steuerung des Multiprogramming-Betriebs
- Durchführung DVS-Ein-/Ausgaben
- Durchführung Paging

Bei voll ausgelasteter CPU gelten folgende Richtwerte:

Der SIH-Anteil sollte insgesamt 20% (S-Server) bzw. 10% (SX- und SQ-Server) nicht übersteigen – auch bei starker DVS-Ein-/Ausgabe-Tätigkeit.

Der Aufwand für die Steuerung des Multiprogramming-Betriebs bewegt sich bei normalen Lasten zwischen 5 - 10% (S-Server) bzw. 3 - 5% (SX- und SQ-Server) der jeweiligen CPU-Auslastung.

Bei üblicher Last und ausgewogener Konfiguration beträgt der SIH-Anteil für die

- Durchführung der DVS-Ein-/Ausgaben: 3 - 6% (S-Server)
  bzw. 2 - 4% (SX- und SQ-Server)
- Durchführung des Paging: max. 2% (S-Server) bzw. max. 1% (SX- und SQ-Server)

Bei der Interpretation der mit SM2 gemessenen Werte wird empfohlen, in der Reihenfolge der anschließend beschriebenen Abschnitte vorzugehen.

10.3.2.1 Auslastung der Ein-/Ausgabe-Peripherie

Richtwerte für die DVS-Ein-/Ausgaberate

Im Abschnitt „Richtwerte für die BS2000/OSD-Server“ auf Seite 353 sind Anhaltspunkte für die maximal sinnvolle Ein-/Ausgaberate in Abhängigkeit vom CPU-Typ zu finden. Diese Richtwerte sind bestimmt nach der Regel, dass nicht mehr als ein gewisser Anteil der CPU-Leistung (bei S-Servern 15 - 25% bzw. bei SX- und SQ-Servern 12 - 16% im Funktionszustand SIH+TPR) für die Einleitung und Behandlung von Ein-/Ausgaben verbraucht werden soll.
Es ist möglich, dass die Richtwerte in einzelnen Fällen deutlich überschritten werden. Dies kann durchaus eine sinnvolle Anwendung sein. Bei Überschreiten der empfohlenen Werte sollte stets durch Einzelprüfung entschieden werden, ob ein Leistungsproblem vorliegt.

ANALYZER-Reports zur Beurteilung der DVS-Ein-/Ausgaberate

Reportgruppe	Report	Bedeutung
IO	IOs for device classes	Anzahl DVS-Ein-/Ausgaben/s
CATEGORY-IO	IOs for category	Anzahl DVS-Ein-/Ausgaben/s je Task-Kategorie
PFA-CACHE	Caching read	Anzahl Lesezugriffe/s auf HIPERFILEs
	Fast write	Anzahl Schreibzugriffe/s auf HIPERFILEs
SYMMETRIX-CONTROLLER	Reads for controller	Anzahl Lesezugriffe/s pro SYMMETRIX-CONTROLLER (Kanal Typ S)
	Writes for controller	Anzahl Schreibzugriffe/s pro SYMMETRIX-CONTROLLER (Kanal Typ S)
	Reads + writes for controller	Gesamtanzahl Zugriffe/s pro SYMMETRIX-CONTROLLER (Kanal Typ S)
STORAGE-SYSTEM-SYMMETRIX	Reads	Anzahl Lesezugriffe/s pro SYMMETRIX -SYSTEM (Kanal Typ FC / S)
	Writes	Anzahl Schreibzugriffe/s pro SYMMETRIX -SYSTEM (Kanal Typ FC / S)
	Reads + writes	Gesamtanzahl Zugriffe/s pro SYMMETRIX -SYSTEM (Kanal Typ FC / S)
	Sequential reads	Anzahl sequenzielle Lesezugriffe/s pro SYMMETRIX -SYSTEM (Kanal Typ FC / S)

Mit SHC-OSD werden die Daten für Symmetrix-Systeme mit dem Messprogramm STORAGE-SYSTEM erfasst (Reports der Reportgruppe STORAGE-SYSTEM-SYMMETRIX). Ohne SHC-OSD werden die Daten der Symmetrix-Systeme mit dem Messprogramm PFA erfasst (Reports der Reportgruppe SYMMETRIX-CONTROLLER), allerdings nur, wenn diese über Typ S-Kanäle angeschlossen sind.

Tuning-Ansätze zur Reduzierung der DVS-Ein-/Ausgaberate
(nicht nach allgemeiner Wichtigkeit sortiert!)

- Reorganisation der ISAM-Dateien
  Verringerung der Anzahl Indexstufen durch organisatorische Maßnahmen (Aufteilung der Datenbestände, Überprüfung auf Aktualität der Daten).
- Umstellung auf NK-ISAM-Dateien und damit Einsparung von Ein-/Ausgaben durch den Einsatz selbst konfigurierender bzw. benutzerspezifisch einstellbarer ISAM-Pools
  Mit Hilfe der Reports der Reportgruppe ISAM-POOL bzw. ISAM-FILE kann die Nutzung der ISAM-Pools überwacht werden:

Report	Messgröße	Bedeutung
Fix operations	Number of fix-hit operations	Anzahl ISAM-Zugriffe/s, die aus dem ISAM-Pool befriedigt wurden
	Number of fix-IO operations	Anzahl ISAM-Zugriffe/s, die zu einer Ein-/Ausgabe auf Platte (Lesezugriff) geführt haben
	Number of fix-wait operations	Anzahl ISAM-Zugriffe/s, bei denen auf das Freiwerden von Pool-Seiten gewartet werden musste
Slot operations	Number of reserve slot wait operations	Anzahl der Wartezustände/s aufgrund von Engpässen bei der internen Pool-Verwaltung infolge eines zu kleinen Pools
Used pages	Number of total pages	Anzahl PAM-Blöcke des ISAM-Pools, die nach Abzug des Platzbedarfs für Verwaltungsdaten zur Pufferung zur Verfügung stehen
Index operations	Number index operations	Anzahl der Index-Zugriffe insgesamt
	Number index hit operations	Anteil der Index-Zugriffe, die aus dem ISAM-Pool befriedigt werden

Die Größe des ISAM-Pools ist richtig dimensioniert (genaue Berechnung siehe Handbuch „DVS-Makros“ [9]) bei einem Verhältnis:

$$\frac{\#\text{FIX-HIT OPERATIONS}}{\#\text{FIX-HIT OPERATIONS} + \#\text{FIX-IO OPERATIONS}} \geq 0{,}85$$

Gleichzeitig muss erfüllt sein:

```
Number of fix-wait operations = 0
Number of reserve slot wait operations = 0
```

Voraussetzung für das Anlegen entsprechend großer ISAM-Pools ist eine ausreichende Hauptspeicher-Kapazität, damit nicht der Effekt der Einsparung von DVS-Ein-/Ausgaben durch eine erhöhte Anzahl von Paging-Ein-/Ausgaben kompensiert wird.

- Erhöhung der Blockungsfaktoren (bei Platten- und Bandverarbeitung)
  Die Erhöhung der Blockgröße ist immer dann ratsam, wenn sequenzielle Verarbeitung vorliegt. Bei wahlfreier Verarbeitung (PAM, ISAM) muss diese Bedingung im Einzelfall geprüft werden. Die Erhöhung der Blocklänge vermindert die Anzahl der Ein-/Ausgaben und entlastet damit das Gerät und die CPU, nicht jedoch den Kanal.
- Vergrößerung der internen Datenpuffer bei Datenbankanwendungen (siehe jeweilige Datenbank-Benutzerhandbücher)
  Immer wenn durch größere interne Puffer der Benutzer-Adressraum entsprechend größer wird, muss auch genügend Hauptspeicher bereitgestellt werden.
- Verringerung der Ein-/Ausgaberate auf die KDCFILE bei UTM-Anwendungen durch Vergrößerung des UTM-Cache-Bereichs (siehe Handbuch „openUTM Anwendungen administrieren“ [21]).
- Einsatz von DAB (ADM-PFA)
  Durch das Lesen von bis zu 16 PAM-Blöcken (32 PAM-Blöcken bei AutoDAB) ergibt sich bei überwiegend sequenzieller Verarbeitung eine deutliche Einsparung an Ein-/Ausgaben. Voraussetzung ist ein genügend großer Hauptspeicher und eine entsprechende CPU-Reservekapazität (durch Reduzierung der zeitlichen Verzögerungen bei der physikalischen Ein-/Ausgabe erhöht sich die CPU-Intensität; zur Handhabung siehe Handbuch „DAB“ [6]).
  Mit Hilfe der Reports „Reads for internal area“ und „Writes for internal area“ der Reportgruppe DAB kann die Trefferrate auf die spezifizierten DAB-Teilbereiche überprüft werden. Bei Einsatz des AutoDAB gibt `/SHOW-DAB-CACHING` einen Überblick über die Dateien, die aktuell dem Caching unterliegen. Siehe auch den Abschnitt „ADM-PFA-Caching“ auf Seite 199.

  Bei SX100 und reiner Nutzung von internen Platten wird zur Beschleunigung der Ein-/Ausgaben der Einsatz von DAB empfohlen, insbesondere, wenn auf dem Vorgängersystem mit Plattencaches gearbeitet wurde. Allerdings können damit die Schreib-Ein-/Ausgaben nicht beschleunigt werden.
- Einsatz von HIPERFILEs unter Nutzung der Cache-Medien Haupt- und Globalspeicher (siehe Abschnitt „Arbeiten mit HIPERFILEs“ auf Seite 195)

Liegt der gemeinsame Wert für die DVS-Ein-/Ausgaberate (siehe den Abschnitt „Richtwerte für die BS2000/OSD-Server“ auf Seite 353) unter dem angegebenen Richtwert, so ist als nächster Schritt die Überprüfung der Auslastung der Kanäle und der angeschlossenen Peripheriegeräte erforderlich.

Richtwerte für die Kanalauslastung

Bei Kanälen mit angeschlossenen Plattenspeichersystemen vom Typ Symmetrix sollte die Auslastung 60% nicht überschreiten. Dies gilt sowohl für den Native-Betrieb als auch den Betrieb unter VM2000 (siehe auch Hinweise zum „Report „Utilization“ der Reportgruppe CHANNEL“ auf Seite 298).

Bei den Magnetbandkassettensystemen 3590 und 3591 ist wegen der gepufferten Betriebsweise eine Kanalauslastung bis 100% möglich.

Reports der Reportgruppe CHANNEL zur Beurteilung der Kanalauslastung

Report	Bedeutung
Utilization	Kanalauslastung (channel busy state)
Data transfer	Anzahl übertragener PAM-Blöcke
IOs	Anzahl Ein-/Ausgaben pro Kanal

Tuning-Ansatz bei Kanalüberlast: Rekonfigurierung

Bei Symmetrix-Systemen sind i.d.R. alle Kanäle, die zu **einer** Symmetrix-Box gehören, relativ gleichmäßig ausgelastet. Kurzfristige Überlastungen (15 Minuten) aus anwendungstechnischen Gründen sind tolerierbar.
Bei länger andauernden Überlastungen müssen mehr Kanäle bereitgestellt werden. Sind Kanäle vom Typ S im Einsatz, ist der Austausch gegen Kanäle vom Typ FC zu empfehlen, siehe Seite 44.

Richtwerte für die Geräteauslastung

Platten (genauer: logische Volumes)

Werden Volumes von mehreren Anwendern gemeinsam benutzt, so ist die Höhe der Auslastung ein wesentliches Kriterium für die Wartezeit vor dem jeweiligen Volume. Bei Online-Anwendungen sollte die Wartezeit nicht höher als ein Drittel der Hardware-Bedienzeit sein.

Wesentlich ist daher die Unterscheidung, ob es sich um ein Volume handelt, das gemeinsam von mehreren Anwendern (bzw. Tasks) benutzt wird, oder ob es einem Anwender fest zugeordnet ist.

Bei gemeinsam von mehreren Anwendern (bzw. Tasks) simultan benutzten Volumes (Public-Volumes, Private-Volumes mit z.B. einer UTM-Anwendung mit mehreren Tasks, Shared-Private-Volumes, Shared-Public-Volumes) sollte die Auslastung 30% (bezogen auf 15 min) nicht übersteigen.

Bei Einsatz der Funktion PAV stehen pro Volume (Basis-Gerät) mehrere Geräteadressen (Alias-Geräte) zur Verfügung, über die gleichzeitig Ein-/Ausgabe-Aufträge abgewickelt werden können (siehe auch Seite 69). Eine höhere Auslastung des Basis-Gerätes (nicht

sichtbar, da SM2 den Mittelwert über Basis-Gerät und Alias-Geräten bildet) führt daher nicht zu einer größeren Wartezeit vor dem Volume. Die nach außen sichtbare Volume-Auslastung (≙ dem Mittelwert über Basis- und Alias-Geräten) sollte 30% nicht übersteigen.

Bei Volumes, die nur einem Anwender (bzw. einer Task) zugeordnet sind, ist eine Auslastung bis 100% vertretbar.

Magnetbandkassettengeräte

MBK-Geräte sind gewöhnlich einer Task fest zugeordnet. Daher ist eine Auslastung bis 100% vertretbar.

Hier ist darauf zu achten, dass die Auslastung nicht durch die „Verarbeitung“ allzu vieler Blocklücken in die Höhe getrieben wird.

ANALYZER-Reports zur Beurteilung der Geräteauslastung (Volumes)

Reportgruppe	Report	Bedeutung
CATEGORY-IO	Duration of non paging IOs for category	Hardware- und Software-Bedienzeit für DVS-Ein-/Ausgaben pro Task-Kategorie
	Duration of paging IOs for category	Hardware- und Software-Bedienzeit für Paging-Ein-/Ausgaben pro Task-Kategorie
DISK	Utilization	Auslastung pro Volume; Die Auslastung wird jeweils aufgeschlüsselt in die Anteile für DVS-und Paging-Ein-/Ausgaben.
	IOs	Anzahl Ein-/Ausgaben pro Sekunde und Volume
	Queue length	Durchschnittliche Warteschlangenlänge vor den einzelnen Volumes
	Data per IO	Anzahl PAM-Blöcke pro Ein-/Ausgabe und Volume
	Time	Hardware- und Software-Bedienzeit für DVS-Ein-/Ausgaben pro Volume
	Number alias devices	Anzahl Alias-Geräte pro Basis-Gerät
SYMMETRIX-DEVICE	Reads for device	Anzahl Lesezugriffe/s und Hit-Rate pro SYMMETRIX-DEVICE (Kanal Typ S)
	Writes for device	Anzahl Schreibzugriffe/s und Hit-Rate pro SYMMETRIX-DEVICE (Kanal Typ S)
	Reads + writes for device	Gesamtanzahl Zugriffe/s und Hit-Rate pro SYMMETRIX-DEVICE (Kanal Typ S)
SYMMETRIX-PUBSET	Reads for pubset	Anzahl Lesezugriffe/s und Hit-Rate pro SYMMETRIX-PUBSET (Kanal Typ S)
	Writes for pubset	Anzahl Schreibzugriffe/s und Hit-Rate pro SYMMETRIX-PUBSET (Kanal Typ S)

Reportgruppe	Report	Bedeutung
SYMMETRIX-PUBSET (Forts.)	Reads + writes for pubset	Gesamtanzahl Zugriffe/s und Hit-Rate pro SYMMETRIX-PUBSET (Kanal Typ S)
SERVICETIME	Duration of IOs for device	Hardware-Bedienzeit für Ein-/Ausgaben pro Volume mit Detail-Aufschlüsselung sowie der Wartezeit vor dem Volume
STORAGE-SYSTEM-SYMMETRIX	Pubset reads	Anzahl Lesezugriffe/s und Hit-Rate pro SYMMETRIX-PUBSET (Kanal Typ FC / S)
	Pubset writes	Anzahl Schreibzugriffe/s und Hit-Rate pro SYMMETRIX-PUBSET (Kanal Typ FC / S)
	Pubset reads + writes	Gesamtanzahl Zugriffe/s und Hit-Rate pro SYMMETRIX-PUBSET (Kanal Typ FC / S)
	Pubset sequential reads	Anzahl sequenzielle Lesezugriffe/s und Hit-Rate pro SYMMETRIX-PUBSET (Kanal Typ FC / S)
	Device reads	Anzahl Lesezugriffe/s und Hit-Rate pro SYMMETRIX-DEVICE (Kanal Typ FC / S)
	Device writes	Anzahl Schreibzugriffe/s und Hit-Rate pro SYMMETRIX-DEVICE (Kanal Typ FC / S)
	Device reads + writes	Gesamtanzahl Zugriffe/s und Hit-Rate pro SYMMETRIX-DEVICE (Kanal Typ FC / S)
	Device sequential reads	Anzahl sequenzielle Lesezugriffe/s und Hit-Rate pro SYMMETRIX-DEVICE (Kanal Typ FC / S)
	Device sequential writes	Anzahl sequenzielle Schreibzugriffe/s und Hit-Rate pro SYMMETRIX-DEVICE (Kanal Typ FC / S)
	Physical disk IOs	Gesamtanzahl Zugriffe/s und Schreibzugriffe/s pro physikalischem Plattenlaufwerk (Kanal Typ FC / S)
	Director IOs	Gesamtanzahl Zugriffe/s und Hit-Rate pro Channel-Director (Kanal Typ FC / S)

i Mit SHC-OSD werden die Daten für Symmetrix-Systeme mit dem Messprogramm STORAGE-SYSTEM erfasst (Reports der Reportgruppe STORAGE-SYSTEM-SYMMETRIX). Ohne SHC-OSD werden die Daten der Symmetrix-Systeme mit dem Messprogramm PFA erfasst (Reports der Reportgruppe SYMMETRIX-CONTROLLER), allerdings nur, wenn diese über Typ-S-Kanäle angeschlossen sind.

Tuning-Ansätze bei Geräteüberlast (Volumes)

Grundsätzlich ist zunächst die Überprüfung der Hardware-Bedienzeit (Report „Time“ der Reportgruppe DISK bei eingeschaltetem Messprogramm SAMPLING-DEVICE), unter Berücksichtigung der Anzahl übertragener PAM-Blöcke pro Ein-/Ausgabe, zweckmäßig.

In sehr seltenen Fällen muss die Analyse wie folgt fortgesetzt werden:

a) Ist die Hardware-Bedienzeit unwesentlich größer als DEVICE CONNECT TIME (Messprogramm bzw. Report „Duration of IOs for device“ der Reportgruppe SERVICE-TIME), so handelt es sich um Read-Hits bzw. Fast-Write-Hits.

   Die Überlastung des logischen Volumes entsteht durch die Häufigkeit der Zugriffe und führt zu Wartezeiten der Tasks vor dem Volume. In diesem Fall ist der Einsatz der Funktion PAV sinnvoll. Andernfalls ist die Auslagerung besonders häufig benutzter Dateien auf andere, weniger ausgelastete Volumes (möglichst auch auf ein anderes physikalisches Laufwerk) erforderlich.

b) Enthält die Hardware-Bedienzeit einen deutlichen Anteil DEVICE DISCONNECT TIME (Report „Duration of IOs for device“ der Reportgruppe SERVICETIME), können folgende Ursachen vorliegen:

   – Unzureichende Unterstützung des Read-Cachings wegen zu kleinem Cache (Read-Hit-Rate zu klein, Report „Reads for device“ der Reportgruppe SYMMETRIX-DEVICE bzw. Report „Device reads“ der Reportgruppe STORAGE-SYSTEM-SYMMETRIX).

   – Durch fehlende „Erholungsphasen“ bei Dauerschreiblasten können Cache-Inhalte nicht zwischenzeitlich auf Platte gesichert werden (hoher Anteil Delayed-Fast-Writes, erkennbar durch eine Write-Hit-Rate < 100 %, Report „Writes for device“ der Reportgruppe SYMMETRIX-DEVICE bzw. Report „Device writes“ der Reportgruppe STORAGE-SYSTEM-SYMMETRIX).

   – Konkurrenzsituation zwischen logischen Volumes, die auf dem gleichen Plattenlaufwerk liegen (Überprüfung der Volumes pro Plattenlaufwerk mit dem Kommando `/SHOW-SYMMETRIX-DEVICE-CONFIG UNIT=*BY-VOLUME (...), INF=*PHYSICAL` des Softwareprodukts SHC-OSD; Kontrolle mit Report „Physical Disk IOs“ der Reportgruppe STORAGE-SYSTEM-SYMMETRIX).

c) Ein Anteil REMAINING SERVICE TIME (Report „Duration of IOs for device“ der Reportgruppe SERVICETIME) in der Hardware-Bedienzeit weist auf folgende Ursachen hin:

- Dehnung der Hardware-Bedienzeit durch andere Gastsysteme unter VM2000.
  In diesem Fall ist die Überprüfung der CPU-Quoten-Einstellung zweckmäßig.
- Einsatz von SRDF (siehe Seite 63).
  Bei CKD-Formatierung liegt der Anteil REMAINING SERVICE TIME in der gleichen Größenordnung wie DEVICE CONNECT TIME. Ist der Anteil REMAINING SERVICE TIME deutlich höher als DEVICE CONNECT TIME, so sind die „Remote Data Links“ nicht leistungsfähig genug, d.h. ihre Anzahl muss erhöht werden.
  Bei FBA-Formatierung ist die DEVICE CONNECT TIME höher als es der zu übertragenden Datenmenge entspricht (dies ist eine Eigenschaft des FBA-Protokolls: die Diskonnektierung erfolgt später als bei CKD-Formatierung). Ein Anteil REMAINING SERVICE TIME der gleich groß ist wie DEVICE CONNECT TIME weist auf eine zu geringe Anzahl „Remote Data Links“ hin.

10.3.2.2 Paging-Aktivitäten

Das Charakteristikum der Hauptspeicher-Verwaltung ist der Paging-Mechanismus, der die effiziente Nutzung eines – im Verhältnis zu den virtuellen Adressraumanforderungen relativ kleinen – Hauptspeichers erlaubt.

Da Paging sowohl zu zeitlichen Verzögerungen führt als auch Last auf dem Prozessor und der Plattenperipherie erzeugt, sollten die im Abschnitt „Richtwerte für die BS2000/OSD-Server“ auf Seite 353 angeführten Paging-Raten nicht überschritten werden.

Weiter ist zu beachten, dass eine ausreichende Anzahl Volumes zur Durchführung der Paging-Ein-/Ausgaben verfügbar ist. Pro Volume können ca. 30 Paging-Ein-/Ausgaben pro Sekunde durchgesetzt werden (bei 10% Auslastung und einer Read-Hit-Rate von 70%).

Hinweise über die Ursache der Paging-Rate ergeben sich aus dem Verhältnis des vom System genutzten Speichers (SWS) zur Anzahl der für Paging verfügbaren Hauptspeicher-Seiten (NPP).

Siehe auch die Hinweise zu „Report „Page frames“ der Reportgruppe MEMORY und „Main memory utilization“ der Reportgruppe WORKING-SET“ auf Seite 302.

Die Tabellen im Abschnitt „Richtwerte für die BS2000/OSD-Server“ auf Seite 353 enthalten typische Hauptspeicher-Ausbauten für verschiedene Server. Der tatsächlich benötigte Hauptspeicher-Bedarf hängt von der gefahrenen Last ab. TP- und Dialog-Lasten haben üblicherweise einen deutlich größeren Hauptspeicher-Bedarf als Batch-Lasten.

10.3.2.3 CPU-Auslastung

Das Betriebsmittel CPU wird i.d.R. von vielen Tasks simultan benutzt. Auch hier ist die Auslastung ein wesentliches Kriterium für die Wartezeit einer Task vor dem Betriebsmittel CPU.

Die durchschnittliche Hardware-Bedienzeit des Betriebsmittels CPU pro Anwenderanforderung (z.B. zwischen zwei DVS-Ein-/Ausgaben) ist vergleichbar klein gegenüber der Durchführung der Ein-/Ausgabe.

Die Wartezeit vor dem Betriebsmittel CPU hat daher auf die Antwort- bzw. Verweilzeit wesentlich geringeren Einfluss als die Wartezeit vor Platten (Volumes). Im Vergleich zu gemeinsam benutzten Volumes ist deshalb eine höhere Auslastung vertretbar, doch sollte für die **Hauptanwendung** eine Auslastung von **70%** nicht überschritten werden (bei Multiprozessor-Servern ist - je nach Anzahl CPUs - eine max. Auslastung bis 90% tolerierbar). Wenn mehrere Gastsysteme genutzt werden, so ist i.d.R. eine um 5 - 15% höhere Gesamtauslastung als im Native-Betrieb möglich.

Zusätzlich erlaubt die Systemsteuerung (PRIOR) die Bevorzugung von Tasks mit Hilfe der Prioritätsvergabe. Damit ist es möglich, auch einen Teil der restlichen **30%** (bzw. 10%) durch **niederpriore Tasks** (mit entsprechend langen Wartezeiten vor dem Betriebsmittel CPU) zu nutzen. Eine CPU-Auslastung von 100% ohne jegliche Beeinträchtigung der Hauptanwendung wird nur in Ausnahmefällen möglich sein.

ANALYZER-Reports zur Beurteilung der CPU-Auslastung

Reportgruppe	Report	Bedeutung
CATEGORY-CPU	CPU utilization (TU+TPR) for category	CPU-Auslastung in den Funktionszuständen TU und TPR pro Task-Kategorie
CPU	Utilization real	CPU-Auslastung in den Funktionszuständen TU, TPR und SIH (echte Werte); Dieser Report ist bei VM2000-Einsatz wichtig, um den CPU-Anteil des gemessenen Gastsystems am Gesamtsystem zu ermitteln.
	Active logical machines	Anzahl aktiver logischer Maschinen (Anzahl der von BS2000/OSD genutzten CPUs)
	Sum SVC calls	Summe aller SVC-Aufrufe in den Funktionszuständen TU und TPR

Hohe CPU-Auslastung

Von einer hohen CPU-Auslastung wird gesprochen, wenn eine Auslastung > 90% vorliegt.

Eine hohe CPU-Auslastung bedeutet nicht zwangsläufig, dass das Betriebsmittel CPU der Engpass ist.

Wird eine hohe CPU-Auslastung festgestellt (Voraussetzung: die Anzahl der von BS2000/OSD genutzten CPUs stimmt mit der Anzahl der tatsächlich verfügbaren CPUs überein), muss zunächst überprüft werden, ob auch eine effiziente Nutzung des Betriebsmittels CPU vorliegt.
Dazu dient das Verhältnis der Auslastung in den Funktionszuständen TU und TPR zur Auslastung im Funktionszustand SIH
(siehe dazu Anmerkungen zu Report „Utilization normed“, Seite 299).

Anzustreben ist das Verhältnis:
`TU + TPR > 3 * SIH` (S-Server) bzw. `TU + TPR > 7 * SIH` (SX- und SQ-Server)

Bei Vorliegen eines ungünstigeren Verhältnisses muss die Untersuchung in Richtung Reduzierung der für den Anwender im Wesentlichen nicht produktiven SIH-Zeit erfolgen:

- Überprüfen der Höhe der DVS-Ein-/Ausgaberate (siehe Abschnitt „Auslastung der Ein-/Ausgabe-Peripherie“ auf Seite 312).
- Überprüfen der Höhe der Paging-Rate (siehe Abschnitt „Paging-Aktivitäten“ auf Seite 319).
- Aufrufe an BS2000/OSD werden grundsätzlich über SVCs abgewickelt. Die Bearbeitung der SVC-Unterbrechung bedeutet einen entsprechenden Aufwand im System, welcher der aufrufenden Task verrechnet wird.

Werden die in den Tabellen im Abschnitt „Richtwerte für die BS2000/OSD-Server“ auf Seite 353 dargestellten SVC-Aufrufe pro Sekunde erreicht, so beträgt der Aufwand für die Unterbrechungsanalyse und Abschlussbehandlung der Systemroutine (also nicht der Aufwand für die Systemroutine selbst) ca. 5% der CPU-Zeit.

Die Gesamtanzahl der SVCs kann über den Report „Sum SVC calls“ ermittelt werden. Mit dem Messprogramm TASK des SM2 kann die SVC-Anzahl taskspezifisch gemessen werden. Die weitere Aufschlüsselung in Form einer SVC-Statistik ist durch eine Benutzer-Task-Messung für ausgewählte Tasks mit anschließender Auswertung durch SM2-PA möglich.

Zur Beurteilung der Frage, inwieweit das Betriebsmittel CPU bei hoher CPU-Auslastung **und** effizienter Nutzung den Engpass bildet, dient das Verhältnis:

```
Wartezeit auf Benutzung der CPU
  Hardware-Bedienzeit der CPU
```

Richtwert

Das Betriebsmittel CPU kann als überlastet angesehen werden, wenn sich für die Hauptanwendung ein Verhältnis:

$$\frac{\text{Wartezeit auf Benutzung der CPU}}{\text{Hardware-Bedienzeit der CPU}} > 3$$

bzw. für die Hintergrundanwendung ein entsprechend größeres Verhältnis ergibt.

Treten für die Hauptanwendung größere Wartezeiten bezüglich Benutzung des Betriebsmittels CPU auf, so können zwei Gründe vorliegen:

- Die Einstellung der Systemsteuerparameter (insbesondere die Prioritätsvergabe) entspricht nicht den Erfordernissen.
- Der CPU-Zeit-Gesamtbedarf aller Tasks ist zu hoch (kritischer Fall).

Nähere Hinweise dazu geben die prozentualen Verweilzeiten in den System-Warteschlangen des SM2-Messprogramms SYSTEM (Auswertung mit SM2R1-Anweisung `//PRINT-QUEUE-TRANSITION`).

Beispiel 1

CPU-Auslastung:	96%
TU-Anteil:	36%
TPR-Anteil:	45%
SIH-Anteil:	15%

Hauptanwendung ⟶ Task-Kategorie TP: $\frac{\text{Verweilzeit[\%]in Q1}}{\text{Verweilzeit[\%]CPU}} = \frac{5{,}4\%}{1{,}2\%} = 4{,}5$

Hintergrundanwendung ⟶ Task-Kategorie Batch: $\frac{\text{Verweilzeit[\%]in Q1}}{\text{Verweilzeit[\%]CPU}} = \frac{2{,}1\%}{1{,}4\%} = 1{,}5$

Durch ungünstige Einstellung der Systemsteuerparameter läuft die geplante Hintergrundanwendung Batch nicht im Hintergrund, wodurch die Tasks der Hauptanwendung TP zu lange auf Benutzung der CPU warten müssen.

Abhilfe: Vergabe einer höheren Priorität für die Hauptanwendung TP oder die Nutzung von PCS (siehe Abschnitt „Einführung in das PCS-Konzept“ auf Seite 243).

Aus den prozentualen Verweilzeiten in den System-Warteschlangen kann **nicht** auf die CPU-Auslastung geschlossen werden.
(Die Summe der Verweilzeiten in allen System-Warteschlangen ergibt 100%.)

Beispiel 2

CPU-Auslastung:	96%
TU-Anteil:	36%
TPR-Anteil:	45%
SIH-Anteil:	15%

Hauptanwendung ⟶ Task-Kategorie TP: $\frac{\text{Verweilzeit[\%]in Q1}}{\text{Verweilzeit[\%]CPU}} = \frac{5,4\%}{1,2\%} = 4,5$

Hintergrundanwendung ⟶ Task-Kategorie Batch: $\frac{\text{Verweilzeit[\%]in Q1}}{\text{Verweilzeit[\%]CPU}} = \frac{16,8\%}{1,4\%} = 12$

Der CPU-Zeit-Gesamtbedarf aller Tasks ist zu hoch. Das Betriebsmittel CPU ist überlastet.

Werden die Leistungsanforderungen der einzelnen Anwender bei hoher CPU-Auslastung trotz effizienter Nutzung und kurzer Wartezeiten auf die Benutzung des Betriebsmittels CPU nicht erfüllt, so ist der Betriebsmittelbedarf pro Anwenderanforderung (z.B. CPU-Zeitbedarf pro Transaktion) zu hoch (siehe Abschnitt „Untersuchen eines anwenderorientierten Leistungsproblems“ auf Seite 326).

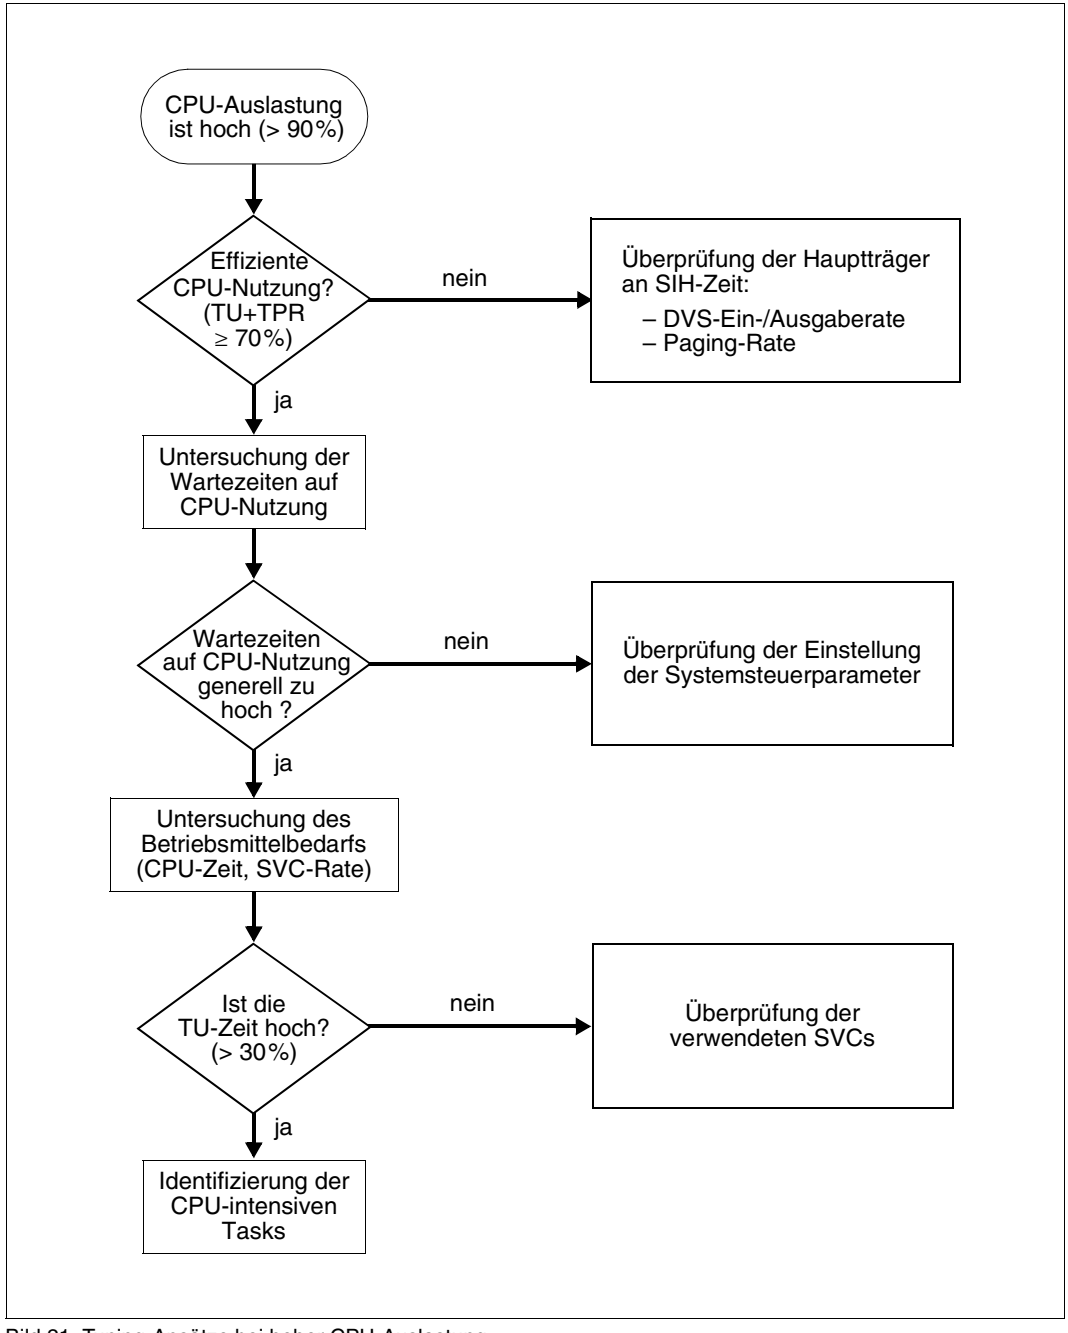

Bild 21: Tuning-Ansätze bei hoher CPU-Auslastung

Niedrige CPU-Auslastung

Treten Leistungsprobleme auf, ohne dass das Betriebsmittel CPU entsprechend ausgelastet ist (< 90%), so können folgende Gründe vorliegen:

- Konfliktsituation auf der DVS-Ein-/Ausgabe-Seite
  (siehe Abschnitt „Auslastung der Ein-/Ausgabe-Peripherie“ auf Seite 312)

  Besonders unangenehm wirkt sich die Überlastung von Volumes aus, auf denen sich Dateien befinden, die von vielen Anwendern gleichermaßen benötigt werden (z.B. bestimmte Anwender-Steuerdateien bzw. die Systemdateien TSOSCAT oder SYSEAM).

  Mit dem SM2-Messprogramm FILE kann die Anzahl der Ein-/Ausgaben auf diese Dateien ermittelt werden.

- Zu hohe Paging-Rate (siehe Abschnitt „Paging-Aktivitäten“ auf Seite 319)

  Bei gravierendem Hauptspeicher-Mangel (dadurch gekennzeichnet, dass die angegebenen Richtwerte für die Paging-Rate bei weitem überschritten werden) ergeben sich Engpässe auf den Public-Volumes bezüglich durchzuführender Paging-Ein-/Ausgaben pro Sekunde, die zu einem erzwungenen CPU-Wartezustand (IDLE) führen.

- Verzögerungen durch PASS/VPASS-Aufrufe

  Bei allzu häufigen Aufrufen der SVCs PASS/VPASS werden Tasks zu oft in den Wartezustand versetzt und können die CPU nicht belegen.

- Engpässe durch Server-Tasks

  Es gibt Anwendungen, die große Teile der Arbeit von spezialisierten Server-Tasks abwickeln lassen. Wird das Fortkommen dieser Tasks durch Paging, Lock-Situationen, Betriebsmittelüberlastung, ungünstige Prioritäten o.ä. behindert, pflanzt sich diese Behinderung auf die gesamte Anwendung fort. Die Server-Task wirkt selbst wie ein Betriebsmittel.

- Ungenügende Parallelverarbeitung durch eine zu geringe Task-Anzahl

  Bei Leistungsbetrachtungen spielen nicht nur die Bedienzeiten der jeweiligen Hardware-Betriebsmittel eine Rolle, sondern auch die Zeit, in der eine Task zur Erfüllung einer gewünschten Anwenderfunktion durch CPU- und Ein-/Ausgabe-Tätigkeit belegt ist.

Beispiel

Beträgt die durchschnittliche Verarbeitungszeit pro Transaktion 0,5 s (0,2 s CPU-Zeit + 0,3 s Ein-/Ausgabezeit), so kann mit einer Task folgende maximale Transaktionsrate (Transaktionen/s) erzielt werden (die Wartezeit auf die entsprechenden Hardware-Betriebsmittel ist nicht berücksichtigt):

$$\frac{1}{0{,}5\ \text{s/Transaktion}} = 2\ \text{Transaktionen/s}$$

Dabei ergibt sich eine CPU-Auslastung von `0,2 * 2 = 0,4`, d.h. 40%.
Eine höhere Transaktionsrate bzw. eine bessere Auslastung des Betriebsmittels CPU lässt sich nur durch eine Erhöhung der Task-Anzahl erreichen (Details siehe Abschnitt „Task-Belegungszeit“ auf Seite 327).

10.3.3 Untersuchen eines anwenderorientierten Leistungsproblems

Das Auffinden der Ursachen von anwenderorientierten Leistungsproblemen ist im Vergleich zur Untersuchung von systemorientierten Leistungsproblemen mit SM2 wesentlich schwieriger.

Bei unbefriedigenden Antwort- bzw. Verweilzeiten bestimmter Anwender ist neben der Beurteilung der globalen Auslastungswerte die Interpretation der taskspezifischen Messwerte erforderlich.

Zusätzlich wird die Durchführung einer SM2-Benutzer-Task-Messung empfohlen:

Über `/START-TASK-MEASUREMENT` wird dem Anwender bzw. der Systembetreuung die Möglichkeit geboten, seine Tasks zur Überwachung anzumelden.
Neben den taskspezifischen Messwerten kann eine PC-Statistik und eine SVC-Statistik der eigenen Task angefordert werden. Die Auswertung der in eine anwenderspezifische Datei geschriebenen Messwerte erfolgt durch das Softwareprodukt SM2-PA (siehe Handbuch „SM2-PA“ [29]).

10.3.3.1 Task-Belegungszeit

Die Task-Belegungszeit besteht aus der CPU-Zeit und der Ein-/Ausgabezeit einer gewünschten Anwenderfunktion sowie der Wartezeit auf die entsprechenden Hardware-Betriebsmittel aufgrund deren Auslastung.

Je größer die Task-Belegungszeit ist, desto geringer ist die Anzahl der Anwenderanforderungen, die durch diese Task pro Zeiteinheit abgefertigt werden können.

Beispiel

Task-Belegungszeit für eine durchschnittliche Transaktion im TP-Betrieb:

Hardware-Bedienzeit der CPU	200 ms
Warten auf CPU (bei 60% CPU-Auslastung, Voraussetzung „M/M/1“)	300 ms
Hardware-Bedienzeit aller Ein-/Ausgaben	400 ms
Warten auf Ein-/Ausgabe (bei 30% Auslastung, Voraussetzung „M/M/1“)	170 ms
	1070 ms

Wird für diese Anwendung während der Zeit der Spitzenbelastung eine größere Transaktionsrate als

$$\frac{1}{1{,}07\ \text{s/Transaktion}} = 0{,}93\ \text{Transaktionen/s}$$

gefordert und steht nur **eine** Task zur Verfügung, so wird diese Task zum Engpass.

Die entstehenden Wartezeiten vor der Task (die eintreffenden Nachrichten stauen sich im BCAM-Puffer) können ein Vielfaches der Task-Belegungszeit erreichen (siehe auch Report „Inwait time distribution“ der Reportgruppe BCAM-CONNECTION, Seite 298).

Hinweise auf die Task-Belegungszeit liefert das SM2-Messprogramm TASK.

Aus den Duration-Angaben für die verschiedenen Wartezustände und die CPU-Zeitaufnahme kann man die Task-Belegungszeit abschätzen. Schwierigkeiten entstehen, wenn man nicht mit Sicherheit sagen kann, ob bestimmte Wartezustände freiwillig oder unfreiwillig sind, d.h. ob ein Task den Service, der für ihn erbracht wird, selbst angefordert hat oder nicht.

Das folgende Verhältnis weist auf eine zu lange Task-Belegungszeit hin:

$$\frac{\text{CPU-Zeit} + \text{CPU-WAIT(Durat)} + \text{DISK-IO-WAITS(Durat)} + \text{NON-DISK-IO-WAITS(Durat)}}{\text{Verweilzeit}} > 0{,}7$$

(Durat = Duration);

In der `Verweilzeit` ist die Wartezeit auf andere Tasks **nicht** enthalten (diese ist also unter Umständen noch dazu zu rechnen).
Die ausgewiesene CPU-Zeit bezieht sich auf die Funktionszustände TU und TPR. Die Zeiten für die Ein-Ausgabe betreffen die Software-Bedienzeit.

10.3.3.2 Behinderungen durch andere Tasks

Konfliktsituationen beim Zugriff auf gemeinsame Hardware-Betriebsmittel (i.W. Public-/Private-Volumes)

Deutliches Anzeichen für die Behinderung durch andere Tasks ist ein SOFTWARE DURATION-Wert (Volume belegt), der mehr als 10% größer ist als der entsprechende Wert HARDWARE DURATION (Ausnahme: asynchrone Ein-/Ausgabe, siehe Erläuterung zu „Report „Time“ der Reportgruppe DISK“ auf Seite 300).

In diesem Fall muss eine Task vor der Einleitung der Ein-/Ausgabe auf das Volume warten, weil dieses tätig ist. Welche anderen Tasks dieses Volume ebenfalls mit Ein-/Ausgaben belegen, kann dem SM2-Messprogramm TASK (mit `INFO=HIGH`) entnommen werden.

Zur Lösung des Problems ist der Einsatz der Funktion PAV oder eine Verlagerung von Dateien notwendig.

Konfliktsituationen bei Veränderung (Update) gemeinsamer Daten

Konfliktsituationen können beim Update gemeinsamer Daten (z.B. Tabellen) entstehen, deren Inhalt für den Betriebsablauf in einem konsistenten Zustand erhalten werden muss.

Konflikte dieser Art können als Zwangs-Serialisierung bezeichnet werden und sind in den taskspezifischen Kenndaten gekennzeichnet durch einen relativ hohen Anteil von:

- „active waits“ bei Serialisierung über den Börsen-Mechanismus bzw. Angabe von Warteaufrufen `VPASS 0`
- „inactive waits“ bei Verwendung des Warteaufrufs `PASS`

Es gibt jedoch viele Fälle, in denen sich ein solcher Zustand mit SM2 durch keinerlei Anzeichen vom normalen Zustand unterscheiden lässt. Anwendersysteme (wie z.B. UTM, UDS, SESAM/SQL, ORACLE) bieten heute eigene Monitore, mit denen man solche Konflikte lokalisieren kann.

Probleme bei mehrstufigen Task-Konzepten (Server-Tasks oder Handler-Tasks)

Sehr häufig werden Funktionen, die allen Tasks gemeinsam sind, herausgezogen und in **einer** Task konzentriert (z.B. Durchführung der Ein-/Ausgabe zu speziellen Datenbeständen oder Datenbankaufrufe).

Wird die Task-Belegungszeit für diese zentrale Task zu lang, so treten für die darauf aufsetzenden Tasks Wartezustände auf.

Ein Engpass vor einer UTM-Anwendung infolge einer zu geringen Anzahl von (UTM-)Server-Tasks kann direkt gemessen werden (siehe die Erklärungen im Abschnitt „Transaktionsbetrieb und BCAM“ auf Seite 208).

Erkennbar sind Wartezustände häufig durch ein Ansteigen der im SM2-Messprogramm TASK ausgewiesenen Anzahl bzw. Zeitdauer der „active waits“ für die aufrufenden Tasks. In der Anzahl „active waits“ ist bei TP-Tasks neben „Warten auf Ein-/Ausgabe“ auch das „Warten auf Terminal-Eingabe“ enthalten. Dieser Anteil ist bei hoher Task-Belegungszeit der zentralen Task vernachlässigbar.

Der Server-Task muss so programmiert sein, dass er keine Sperren benötigt, auf die er gegebenenfalls wartet. Wird er gegenüber anderen Tasks nicht vorrangig behandelt (Priorität), so besteht ebenfalls die Gefahr von plötzlichen Durchsatzeinbrüchen. Durch das Auftragsverfahren zwischen Auftraggeber- und Server-Task kann es im Falle von nicht fehlerfreier Programmierung zu Verklemmungen kommen, die den Server-Task stilllegen. Alle diese Probleme zeigen, dass es sich bei Server-Tasks um ein Coding von besonders hoher Qualität handeln muss.

Beispiel (vereinfacht)

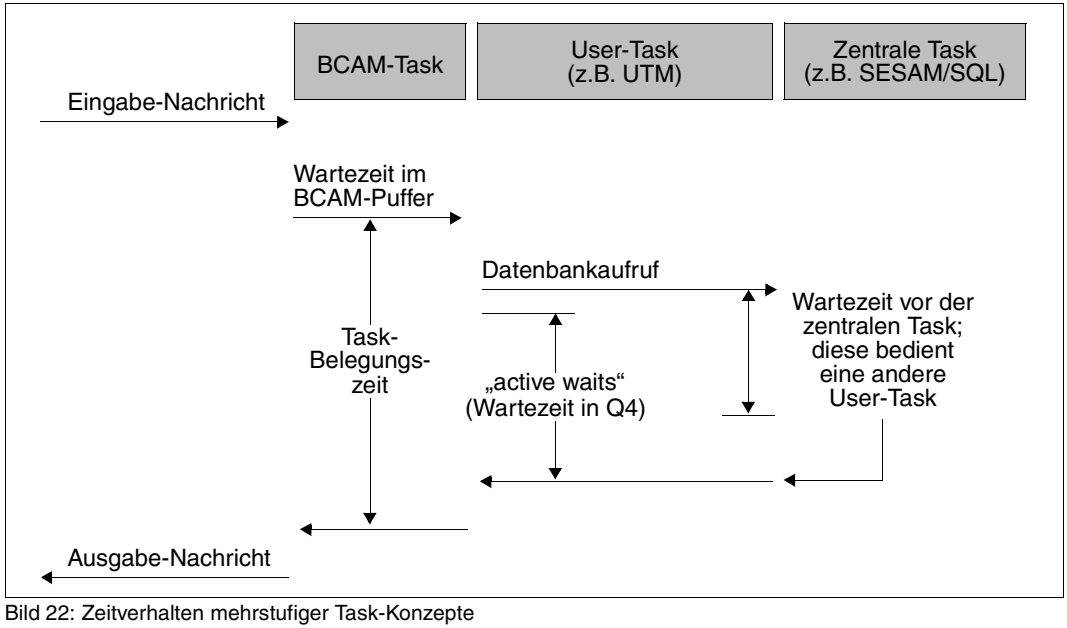

Bild 22: Zeitverhalten mehrstufiger Task-Konzepte

10.3.3.3 Hoher Betriebsmittelbedarf

Werden die Leistungserwartungen der Anwender trotz effizienter Nutzung der Betriebsmittel und kurzer Wartezeiten nicht erfüllt, so deutet dies auf einen zu hohen Betriebsmittelbedarf pro Anwenderanforderung hin (z.B. CPU-Zeitbedarf und/oder Anzahl Ein-/Ausgaben pro Transaktion).

Hinweise auf den Betriebsmittelbedarf ergeben sich aus den durch das SM2-Messprogramm TASK gelieferten Angaben über:

- CPU-Zeitverbrauch
- Anzahl SVC-Aufrufe in TU
- Anzahl DVS-Ein-/Ausgaben

Zur genaueren Untersuchung des Verhaltens von Anwenderprogrammen ist eine SM2-Benutzer-Task-Messung mit einer SM2-PA Auswertung erforderlich:

- Die PC-Statistik bietet die Möglichkeit, diejenigen Programmbereiche zu erkennen, die sehr häufig durchlaufen werden.
- Die SVC-Statistik enthält alle aufgerufenen SVC-Nummern und deren Aufrufadressen.

10.3.4 Einfluss des Netzes

Alle bisherigen Empfehlungen haben sich mit der Verbesserung der Effizienz des zentralen Verarbeitungsrechners befasst. Wie im Kapitel „Leistungserwartungen aus Anwendersicht“ auf Seite 17 ausgeführt, sind gute Transaktionszeiten ein wesentlicher Produktivitätsfaktor. Im Abschnitt „Transaktionsbetrieb und BCAM“ auf Seite 208 werden Maßnahmen zur Antwortzeitoptimierung im Transaktionsbetrieb und bei BCAM beschrieben.
Bild 1 auf Seite 19 zeigt, dass in den Transaktionszeiten die Netzlaufzeiten enthalten sind. Diese Laufzeiten können größer sein als die eigentliche Antwortzeit im Verarbeitungsrechner. Es ist daher in jedem Fall von unbefriedigendem Verhalten zu klären, ob die schlechten Transaktionszeiten nicht durch das Netz verursacht werden.
Weisen die Reports der Reportgruppe BCAM-CONNECTION akzeptable Antwortzeiten aus und werden dennoch an den Terminals überwiegend lange Transaktionszeiten beobachtet, liegt ein Engpass im Netz vor.

Ein Netz ist ein komplexes Gebilde mit vielen Abhängigkeiten. Angesichts der Vielfalt möglicher Netzstrukturen soll nur auf die wesentlichen Merkmale und Randbedingungen hingewiesen werden. Die umfassende Behandlung solcher Probleme sprengt den Rahmen dieses Handbuchs.

Lastanforderungen

Lasttyp	Anforderung
TP-Betrieb oder Dialogbetrieb	kurze Antwortzeit
Datensicherung, File Transfer	Durchsatz
WWW, Mail	Durchsatz, Antwortzeit

Netztypen

a) Vernetzung über WAN (Wide Area Network):

- X.25 Datex-P: bis 64 Kbit/s
- Standleitung: bis 2 Mbit/s

b) Lokaler LAN-Verbund (z.B. PCs verbunden über Inhouse-LANs mit BS2000/OSD):

- Ethernet: 10 Mbit/s
- Fast Ethernet: 100 Mbit/s
- Gigabit Ethernet: 1000 Mbit/s

c) Internet-Working (z.B. Vernetzung mehrerer LAN-Inseln):

- X.25 Datex-P: bis 64 Kbit/s
- Standleitung: bis 2 Mbit/s
- FDDI: 100 Mbit/s
- ATM: 155 Mbit/s

d) Internet mit BS2000/OSD als Server (*Web*Transactions, Mail, Apache)

Beispiele für Netzleistung

- Reine Kommunikationslast ohne interne Verarbeitung
  Konfiguration: Fast Ethernet, Kanaladapter HNC 91852, Server S170-40, 2 Kanäle Typ S, 2 LANs (siehe auch Abschnitt „LAN-Anschluss“ auf Seite 94)
  - 38.000 Transaktionen/s
  - 23 Mbyte/s Datendurchsatz
  - 1,2 ms Antwortzeit
- Netzlaufzeit bei Client/Server Konfiguration (Eingabe: 100 Byte, Ausgabe: 1000 Byte)
  - Client/Server am selben LAN: ca. 2 ms
  - Client über WAN mit Server verbunden: ca. 200 ms

Mögliche Engpässe

- Leistung des Netzanschlusses (z.B. Kanaladapter älteren Typs: HNC 91850)
- Client System (z.B. Hardware-Leistung, Struktur der Anwendung, Networking-Parameter)
- Netzkonfiguration mit Zielkonflikten bezüglich Antwortzeit/Durchsatz (z.B. Parallelbetrieb von transaktions- und durchsatzorientierten Anwendungen)
- Netzstruktur (z.B. Konfiguration von Netzknoten, Router, Switches, Hubs)
- Netzüberlast durch Dritte (z.B. Internet)

10.4 Leistungsbedarf von SM2

Für die Erfassung der Messdaten benötigt SM2 die Ressourcen CPU und Plattenspeicher. Der Bedarf hängt ab:

- von der Art der Messprogramme und ihrer Parametrisierung
- von der Hardware-Konfiguration
- von Lastprofil (i.W. von der Anzahl Tasks und der Ein-/Ausgabe-Intensität)

Insgesamt ist der Ressourcen-Verbrauch durch SM2 relativ gering.
Gelegentlich sollte überprüft werden, ob eine Einschränkung der Messprogramme zur Ressourcen-Entlastung nötig bzw. möglich ist. Eine Einschränkung der Messprogramme geht allerdings zu Lasten der Güte der Performance-Überwachung.

Messwerte

In einem Laborversuch wurde der Ressourcen-Bedarf von SM2 vermessen unter einer typischen OLTP-Last, die den Server zu ca. 70% auslastet.

Dabei wurde folgender CPU-Bedarf von SM2 in absoluten Prozentwerten gemessen:

- 0,5 - 1% für die Basismessung (Messprogramme Standard und SYSTEM)
- zusätzlich 1% für Antwortzeiterfassung und Messprogramm UTM
- zusätzlich 1% für die Nutzung der Messprogramme PERIODIC-TASK und TASK
- zusätzlich 1% für die Nutzung des Messprogramms STORAGE-SYSTEM
  (mit `//SET-STORAGE-SYSTEM-PARAMETERS ADDITIONAL-DATA=*SYMMETRIX(TYPE=(*PHYSICAL-DISK,*DIRECTOR)`),
  sowie dem Einschalten der Ein-/Ausgabe-Zeitmessung der Plattengeräte
  (mit `//SET-SAMPLING-DEVICE-PARAMETERS DISK-SERVICETIME=*ON`).

Diese Werte wurden mit dem Standard-Sampling-Intervall 800 ms gemessen. Bei Änderung des Sampling-Intervalls ändert sich der CPU-Bedarf von SM2 linear mit dem Anteil der periodisch erfassten Daten. Z.B. verringert sich bei der Basismessung mit Antwortzeiterfassung und Messprogramm UTM der CPU-Bedarf von SM2 von 1,5% auf knapp unter 1%, wenn das Sampling-Intervall auf 2000 ms geändert wird.

Für das Ablegen der Messdaten wird Plattenspeicherplatz benötigt. Die Angabe von Richtwerten in absoluten Maßzahlen ist nicht möglich, da der Bedarf zu stark von der jeweiligen Hardware- und Software-Last sowie der Konfiguration der Messprogramme abhängt.
Es ist jedoch zu beachten, dass insbesondere das Messprogramm PERIODIC-TASK (und noch mehr das nicht mehr empfohlene Messprogramm DISK) die Messwertedatei um 50% oder mehr gegenüber der Basismessung anwachsen lässt.

10.5 Weitere Hilfsmittel zur Performance-Analyse

10.5.1 COSMOS

COSMOS ist ein ereignisgesteuerter Monitor für die Erfassung detaillierter Messdaten zur gezielten Performance-Diagnose von BS2000/OSD-Systemen. Es ist ein Messprogramm von SM2 und kann somit über die SM2-Kommandos gesteuert werden.

COSMOS zeichnet den gesamten zeitlichen Ablauf von Systemereignissen auf. Es können ca. 90 verschiedene Arten von Ereignissen registriert werden, z.B. Start und Ende einer Ein-/Ausgabe, Systemaufrufe (SVCs), Erzeugung und Beendigung von Tasks. Jedes Ereignis („Event“) wird durch einen 4 Zeichen langen Namen identifiziert. Zur Erfassung der Ereignisse sind an ausgewählten Punkten im System COSMOS-Schnittstellen, so genannte „Hooks“, implementiert. Abhängig von den gewählten Parametern ist der Hook „geöffnet“, d.h. der Datensammelcode wird bei jedem Eintreten des entsprechenden Ereignisses aktiviert und ein Datensatz geschrieben. Beim Beenden von COSMOS werden alle zu diesem Zeitpunkt geöffneten Hooks geschlossen.

Die Daten können für alle Tasks oder für nach bestimmten Kriterien (Benutzerkennung, Kategorie, Jobname oder TSN) ausgewählte Tasks gesammelt werden.

Die erfassten Messdaten werden in Messwertedateien (auf Band oder Platte) geschrieben. Zur Auswertung der COSMOS-Messwertedateien sind spezielle Auswerteprogramme verfügbar. In der Regel sind Experten-Kenntnisse zur Aus- und Bewertung von COMOS-Messungen nötig.

10.5.2 COPE (Computer Performance Evaluator)

COPE ist ein Verfahren zur Leistungsprognose von IT-Anwendungen in BS2000/OSD. COPE spiegelt modellhaft das Performanceverhalten des Servers wieder. Es eignet sich zu Leistungs- und Kapazitätsplanungen in den Bereichen Entwicklung und Planung neuer IT-Verfahren und Konzepte, IT-Produktion und IT-Investition (Konfigurationsvergleiche, Lastzuwachs und Lastverteilung), Modellierung des VM2000-Betriebs, Modellierung der Auswirkungen von Caches im Hauptspeicher, Global Storage und Steuerungen. Vergleichende Analysen lassen sich einfach und schnell durchführen. Die rechnergestützte Absicherung von Performanceaussagen optimiert und rationalisiert die Planungsarbeit und liefert objektive Entscheidungsgrundlagen.

Funktionen von COPE

COPE baut aus den Lastdaten einer IT-Anwendung (z.B. Pfadlängen, Anzahl Ein-/Ausgaben) für eine bestimmte Konfiguration ein mathematisches Modell auf, das mit Hilfe analytischer Methoden berechnet wird. Man beschreibt die Konfiguration, die Software und deren zugehörige Lastintensität und erhält Aussagen über Durchsätze, Auslastung und Antwortzeiten. Interne Strategien und Abläufe von BS2000/OSD und das Verhalten unter VM2000 sind in COPE integriert. Das Verfahren nutzt eine umfangreiche Datenbasis mit aktuellen Produktkennwerten, Systemstandards, Konfigurationsregeln und Performanceempfehlungen. Durch verfahrenstechnische Ergänzungen, die dem zentralen Dialogprogramm vor- und nachgeschaltet sind, integriert COPE computergestützt Arbeiten im Rahmen der Kapazitätsplanung.

Programmbeschreibung

COPE ist ein dialoggeführtes Programmsystem. Eingaben können schnell und gezielt erfasst und je nach Bedarf modifiziert werden. Dies gilt sowohl für die zentrale Hardware-Konfiguration und die erste Stufe des Netzwerks, als auch für sämtliche Lastdaten. Die gezielte Anpassung der Dialogoberfläche an die Hardware und an BS2000/OSD erlaubt die Beschreibung von Business Servern durch Angabe bzw. Änderung des Produktnamens. Die Auswirkungen dieser Modifikationen auf Leistungsgrößen und Performance lassen sich sofort am Bildschirm erkennen.

COPE ist kein Bestandteil der Softwarekonfiguration von BS2000/OSD.
Es wird aber im Rahmen von Consulting-Dienstleistungen für Leistungs- und Kapazitätsplanungen in BS2000/OSD eingesetzt.
Bitte sprechen Sie gegebenenfalls Ihren Vertriebsbeauftragten an.

11 Optimierungshinweise zur Erstellung von Anwender-Software

Dieses Kapitel gibt Empfehlungen für den optimalen Umgang mit Betriebsmitteln im Rahmen der Dateiverarbeitung sowie Hinweise für das performante Laden von Programmen/Produkten.

11.1 Wahl der Zugriffsmethode

UPAM und BTAM

UPAM und BTAM sind die Basis-Zugriffsmethoden für Platte bzw. Magnetband. Da sie für kleine Anwendungen kaum eine Rolle spielen, sind sie ungerechterweise etwas in Vergessenheit geraten. Bei der Planung eines Verfahrens sollten sie in jedem Fall in Betracht gezogen werden. Sie bieten einige in anderen Zugriffsmethoden nicht verfügbare Funktionen. Häufig ist ihre Anwendung gegenüber anderen Zugriffsmethoden ohne einen Verlust an Anwenderfreundlichkeit bei deutlicher Leistungssteigerung möglich. UPAM z.B. bietet wahlfreie Zugriffe über die „Half Page Number“.

Gemeinsame Vorteile von UPAM und BTAM sind:

- einfache Schnittstelle für das Anwenderprogramm
  Es gibt je nur einen Aktionsaufruf an das DVS. Die gewünschte Aktion wird durch aktuelle Parameter formuliert. Jede Schreib-Lese-Anforderung aus dem Programm bewirkt eine physikalische Ein-/Ausgabe.
  Im Vergleich zu SAM/ISAM: Das datensatzbezogene Blocken/Entblocken entfällt, deshalb arbeiten UPAM und BTAM mit entsprechend kürzeren Pfadlängen.
- Wahlmöglichkeit zwischen synchronen und asynchronen Ein-/Ausgaben
  Asynchrone Ein-/Ausgaben können die Laufzeit eines Programms erheblich abkürzen.
- vollständiger Durchgriff auf die Eigenschaften des Speichermediums, das optimal genutzt werden kann.
- Auftragskettung zur Einsparung von SVCs und gekettete Ein-/Ausgaben zur Einsparung von Systemaufwand (Chained-IO)
- Verarbeitung von Dateien, die mit anderen Zugriffsmethoden erstellt wurden

Zusätzliche Vorteile von UPAM sind:

- schlüsselähnlicher, wahlfreier Zugriff über „Half Page Number“
- Verarbeitung von inhaltlich geschädigten Dateien möglich
- Mehrfachbenutzbarkeit auch bei Aktualisierungen
- Möglichkeit zur Kopplung asynchroner Ein-/Ausgabe-Aufrufe mit Eventing

Zusätzliche Vorteile von BTAM sind:

- Blocklänge innerhalb der von der Hardware gegebenen Minimal- und Maximallänge beliebig wählbar
- Verarbeitung von Datenträgern aus fremden Betriebssystemen möglich

FASTPAM

Für die Zugriffsmethode FASTPAM gilt i.W. alles, was zu UPAM gesagt wird.

Zu beachten sind folgende Einschränkungen:

- Das Dateiformat muss vom Typ NK4 sein (`BLKCTRL=NO`, Blockgröße=ein Vielfaches von 4 KB).
- Zugriffe stets über absolute Blocknummer
- keine Synchronisierungsmechanismen beim Zugriff mehrerer Anwender auf eine Datei
- FASTPAM unterstützt den Multi-System-Verbund mittels Shared-Pubset, aber nicht Shared-Private-Disk bzw. Remote-File-Access.

Der Performance-Gewinn gegenüber UPAM ergibt sich dadurch, dass die für Ein-/Ausgaben erforderlichen Initialisierungs- und Validierungsroutinen nicht bei jeder Ein-/Ausgabe durchlaufen werden, sondern nur einmal vor der Dateieröffnung.

Der Anwender definiert vor dem OPEN eine Systemumgebung, bestehend aus ENVIRONMENT und IO-AREA-POOL. Dies sind System- und Anwenderspeicherbereiche, die bei den Dateizugriffen immer wieder benutzt werden.

Der maximale Performance-Gewinn ergibt sich, wenn die Systembereiche resident angelegt werden. Voraussetzung ist die Berechtigung im Benutzerkatalog (`DMS-TUNING-RESOURCES=*EXCLUSIVE-USE`) sowie eine entsprechende Versorgung des Operanden `RESIDENT-PAGES` im Benutzerkatalog und beim Starten der Task.

SAM

Die Zugriffsmethode SAM ist auf die sequenzielle Verarbeitung von Datensätzen abgestimmt. Sie sollte immer dann gewählt werden, wenn Dateien nicht mehrfachbenutzbar sein sollen und kein wahlfreier Zugriff gefordert ist. Die einfache und doch flexible Satzstruktur gestattet sowohl Sätze fester Länge als auch solche von variabler Länge. Beide Längentypen können je nach Anwendung zur Einsparung von Speicherkapazität beitragen.
Der Verzicht auf Schlüsselzugriffe führt zu einer gegenüber ISAM wesentlich kürzeren Pfadlänge. Die Datei kann im Bedarfsfall einfach (z.B. mit einem Editor) in eine Schlüsseldatei überführt werden.

Vorteile von SAM sind:

- satzweises Lesen und Schreiben
- eingeschränkte Aktualisierungsmöglichkeiten mit hoher Performance (PUTX)
- kurze Programmlaufzeiten durch Vorauslesen des nächsten Blockes
- Datei kann auch mit PAM bearbeitet werden
- hohe Leistung durch Ausschluss der Mehrfachbenutzbarkeit bei Aktualisierungen

ISAM

ISAM ist die höchstentwickelte Zugriffsmethode im BS2000. Sie bietet sehr viele Annehmlichkeiten, die über Speicherungsaufwand und Pfadlängen zu bezahlen sind. In der Praxis kommt es oft vor, dass Dateien aus Gründen der Kompatibilität oder der Zukunftssicherheit als ISAM-Dateien geführt werden, die aber nach ihrer Art und Anwendung typische SAM-Dateien sind (z.B. Quellprogramme). Wegen der leichten Konvertierbarkeit von SAM zu ISAM ist dies nicht erforderlich.

ISAM ist jedoch keine reine Schlüsselzugriffsmethode. ISAM ist optimiert auf Zugriffsfolgen, bei denen einem Schlüsselbegriff eine Reihe von sequenziellen Zugriffen folgt (index-sequenziell). Die Verteilung der Schlüsselhäufigkeit und besonders deren Änderung während der Lebensdauer einer Datei hat Einfluss darauf, wieviele physikalische Ein-/Ausgaben benötigt werden, um einen bestimmten Satz zu lesen. ISAM sollte nur eingesetzt werden, wenn eine oder mehrere der nachfolgenden Eigenschaften benötigt werden:

Vorteile von ISAM sind:

- Schlüsselzugriffe, die weitgehend unabhängig sind von der Schlüsselverteilung und ihrer Änderung
- effektives sequenzielles Lesen nach Schlüsselzugriff
- Mehrfachbenutzbarkeit auch bei Aktualisierungen
- ertragbare Verschlechterung der Zugriffsleistung auch nach extrem umfangreichen einseitigen Erweiterungen

NK-ISAM (Nonkey-ISAM) unterstützt sowohl Platten mit CKD-Format (Count Key Data) als auch mit FBA-Format (Fixed Block Architecture).

Durch die Einführung von ISAM-Pools werden die Index-Bereiche (teilweise auch Datenbereiche) im virtuellen Speicher gehalten. Dies ermöglicht bei index-sequenziellen Zugriffen eine starke Verringerung der physikalischen Ein-/Ausgaben und führt zu deutlichen Laufzeitverkürzungen.

BS2000/OSD automatisiert und optimiert das Anlegen von Pufferbereichen (NK-ISAM-Pools) für NK-ISAM-Dateien, die mit `SHARUPD=YES` geöffnet werden. NK-ISAM-Pools müssen dann nicht mehr konfiguriert werden.

NK-ISAM erlaubt den Einsatz von Sekundärschlüsseln. Werden neben dem Primärschlüssel zusätzliche Ordnungsbegriffe in Form von Sekundärschlüsseln pro logischem Satz geführt, so lässt sich ein gegebener Datenbestand nach verschiedenen Kriterien durchsuchen und verarbeiten.

Im Vergleich zu einer Anwendung ohne Sekundärschlüssel ändert sich der Betriebsmittelbedarf geringfügig, solange der so genannte Indexbaum nicht geändert wird, steigt aber stark an bei Änderungen des Indexbaumes (z.B. bei GET-ELIM, GETKY-ELIM, STORE).

PAM

Neben ISAM sind weitere Schlüsselzugriffsmethoden denkbar, die speziellere Anforderungen besser erfüllen können. BS2000/OSD bietet durch die Zugriffsmethode PAM die Möglichkeit, sich eigene Zugriffsmethoden zu implementieren. Dass dies mit geringem Aufwand möglich ist, zeigt das folgende Beispiel einer HASH-Zugriffsmethode.

Folgende Eigenschaften seien gefordert bzw. gegeben:

- 90% der Zugriffe sollen mit einer Ein-/Ausgabe möglich sein.
- Bestimmte hochfrequentierte Blöcke sollen auch ohne Einsatz von DAB ohne Ein-/Ausgabe gelesen werden können.
- Die Änderungsfrequenz ist hoch, aber es werden nur sehr selten Sätze gelöscht, erzeugt oder stark verlängert.
- Die Schlüsselverteilung ist bekannt und folgt einfach formulierbaren Gesetzen.
- Die Datei wird **nicht** sequenziell gelesen.
- Es steht genügend Speicherkapazität zur Verfügung.

Unter diesen Bedingungen ist durch einen einfachen Algorithmus aus dem Schlüssel die Nummer des Blockes zu ermitteln, in welchem sich der Satz befindet. Der Füllgrad der Blöcke ist so gering, dass die überwiegende Mehrzahl der Aktualisierungen den Block nicht zum Überlauf bringt. Im seltenen Fall eines Blocküberlaufs enthält der Block einen Verweis

auf den Folgeblock und dieser bei Überlauf auf einen weiteren Folgeblock. Die Pufferung von hochfrequentierten Blöcken macht wegen der Eigenimplementierung keinerlei Schwierigkeiten.

Obwohl für jede Schlüsselverteilung ein eigener Umsetzungsalgorithmus Schlüssel zu Blocknummer implementiert werden muss, kann dieses Verfahren gegenüber dem universellen ISAM bei großen Dateien erhebliche Leistungsgewinne bringen.

Datenbanken

Eine wesentliche Erweiterung der Zugriffsmethoden stellen die Datenbanken dar.
Bei Datenbanken sind die Aufwände für Installation und Wartung der Datenbestände sowie die Pfadlängen beim Zugriff größer als bei anderen Zugriffsmethoden.

Dafür bieten Datenbanken folgende weitergehende Eigenschaften:

- Die Organisation der Daten und der Zugriffspfade können vom Anwender definiert und seinen Datenbeständen angepasst werden.
- Nicht beendete Transaktionen können zurückgesetzt werden.
- Durch Logging ist der Datenbestand immer bis auf den Zustand kurz vor dem Zusammenbruch rekonstruierbar.
- Zugriffsrechte können definiert und überwacht werden.
- Durch die Möglichkeit, komplexe Beziehungen zwischen den Datensätzen herzustellen, kann die Datenredundanz verringert werden.
- Durch Suchfragen nach mehreren Schlüsseln mit der Möglichkeit zu logischen Verknüpfungen können Anwenderprogrammteile eingespart werden.

Das Softwareproduct LEASY ist eine Erweiterung der BS2000-Zugriffsmethoden für den TP-Betrieb.
Aufbauend auf ISAM ermöglicht LEASY die Rücksetzbarkeit von Transaktionen und die volle Rekonstruierbarkeit der Datenbestände. Zusätzlich wird ein Zugriff nach Sekundärschlüsseln sowie eine CALL-Schnittstelle angeboten.
Der Einsatz von LEASY ist immer dann zu erwägen, wenn über den TP-Betrieb hinaus keine Datenbankeigenschaften benötigt werden.

DIV

DIV (Data in Virtual) ist eine Zugriffsmethode, die sich von den traditionellen Zugriffsmethoden wie ISAM, SAM oder UPAM dadurch unterscheidet, dass sie ohne Strukturierung der Datei in Sätze oder Blöcke, ohne Ein-/Ausgabe-Puffer und ohne spezielle Ein-/Ausgabe-Makros (wie GET, PUT) auskommt.

DIV bearbeitet nur PAM-Dateien vom Typ NK4 (BLKCTRL=NO, die Blockgröße ist ein Vielfaches von 4 KB).

DIV betrachtet die Datei als eine lineare Byte-Folge. Mit Hilfe der DIV-Funktion MAP kann eine Datei oder ein Dateibereich einem Bereich im virtuellen Adressraum zugeordnet werden. Der einem Dateibereich zugeordnete virtuelle Adressraum bildet dann ein „Fenster“, in dem die Seiten der Datei automatisch erscheinen, wenn auf die entsprechenden Seiten im virtuellen Adressraum mit den üblichen CPU-Befehlen zugegriffen wird. In einem Fenster geänderte Daten können mit der DIV-Funktion SAVE in die Datei geschrieben werden.

Im eingeschwungenen Zustand liegt die Datei bzw. der Dateiteilbereich im Adressraum des Anwenders und ist somit dem Paging unterworfen. Bei großen Dateibereichen und nicht ausreichendem Hauptspeicher steigt die Paging-Rate entsprechend an.

Ein Performance-Gewinn ergibt sich, wenn wiederholt auf Daten im Fenster zugegriffen wird, die durch vorangegangene Zugriffe in das Fenster (über Paging) eingelesen wurden.

DIV-Lesen

Der maximale Performance-Gewinn tritt beim Zugriff auf Daten im Fenster ein, der Plattenzugriff entfällt vollständig.
Muss der Datenzugriff über einen Page-Transfer abgewickelt werden, so ist die Pfadlänge pro Zugriff im Vergleich zum Lesezugriff über UPAM um ca. 20% kürzer.

DIV-Schreiben

Sicheres Schreiben wird realisiert, indem die modifizierte Seite nach jedem Schreibzugriff in die Datei zurückgeschrieben wird (DIV-SAVE). In diesem Fall ist die Pfadlänge pro Zugriff um ca. 35% länger als bei einem UPAM-Schreibzugriff. Der Mehraufwand kann nur durch eine Verringerung der Anzahl SAVE-IOs reduziert werden (z.B. einmalige Sicherung beim CLOSE der Datei). Ist beim Schreibzugriff ein Page-Transfer erforderlich, so ist die Pfadlänge um ca. 10% länger als beim UPAM-Schreibzugriff.

Die Zugriffsmethode hat großen Einfluss auf die Leistung des Gesamtsystems und sollte entsprechend sorgfältig ausgewählt werden.

11.2 Wahl des Bearbeitungsmodus

Im engen Zusammenhang mit den Zugriffsmethoden stehen die Bearbeitungsmodi einer Datei. Diese können zwar bei jeder Bearbeitung neu festgelegt werden, sind jedoch fast immer in das bearbeitende Programm eingebettet und daher festgeschrieben. Sie haben einen ähnlich großen Einfluss auf die Leistung des Systems wie die Zugriffsmethoden und sollten daher mit Sorgfalt ausgewählt werden. In allen drei Phasen der Dateibearbeitung (OPEN, Zugriff, CLOSE) werden explizit oder implizit Moduswahl-Entscheidungen getroffen.

11.2.1 OPEN

Durch den Typ des OPEN-Aufrufs wird bei der Programmerstellung festgelegt, welche Zugriffsmöglichkeiten anderen Anwendern der Datei offenstehen. Es sollte daher eine Selbstverständlichkeit sein, keine über die beabsichtigte Nutzung hinausgehenden Modi zu wählen. Wer nur lesen will und nicht mit INPUT eröffnet, sperrt andere lesende Anwender aus. Bei Dateien von allgemeinem Interesse lohnt sich der Aufwand der Fallunterscheidung „Lesen – Aktualisieren“ schon beim OPEN.

Das Eröffnen einer Datei ist ein komplexer Vorgang. Wegen des damit verbundenen Aufwands sollte er so selten wie möglich ausgeführt werden. Dem sind auch Forderungen nach einer möglichst kurzen Sperrdauer unterzuordnen. Gegebenenfalls muss auf die Zugriffsmethoden PAM oder ISAM mit dem Modus SHARUPD ausgewichen werden.

Kann ein gewisser Verlust an Aktualität hingenommen werden, lohnt sich die Installation einer Datei-Kopie für lesende Zugriffe. Diese sollte schreibgeschützt werden, um sie gegen Anwender abzusichern, die auch die Kopie schreibend eröffnen wollen.
Diese Lösung ist leistungsfähiger, weil der Modus SHARUPD den Aufwand für den Zugriff ansteigen lässt. Ist die Wahrscheinlichkeit einer Kollision klein, lohnen diese Mehraufwendungen nicht.

11.2.2 Zugriffe

Auch hier gilt die Regel, dass nicht mehr als funktional unabdingbar gesperrt werden sollte. Übertriebenes Sicherheitsdenken mindert die Leistung. Eventuell kann durch Zulassen von Überbuchungen oder Entflechten von Sätzen eine Sperre oder gar der SHARUPD-Modus ganz vermieden werden.

Das Erzwingen eines Konsistenzzustandes einer offenen Datei (RELSE-Aufruf) sollte wegen der damit verbundenen physikalischen Ein-/Ausgaben sorgfältig dosiert werden.

Schlüsselzugriffe in ISAM sind aufwendiger als sequenzielle Zugriffe. Gegebenenfalls kann man sie nach Umorganisation des Programms oder der Datei teilweise durch sequenzielle Zugriffe ersetzen.

Muss auf Dateien in einem Mehrrechnersystem zugegriffen werden, sollte man abschätzen, ob sich eine Vorabübertragung der Datei oder von Teilen von ihr lohnt. Das hängt von der Struktur der Datei und der Zugriffe ab. Von erheblicher Bedeutung ist auch, ob ein MRS-Zugriff über das Netz oder über von mehreren Rechnern ansprechbare Platten, die im Shared-Pubset- oder Shared-Private-Disk-Modus betrieben werden, erfolgen kann.

Werden Dateien aufgebaut oder erweitert, kann durch Umgehung der „Secondary Space Allocation“ eine Leistungsverbesserung erzielt werden.

Die dadurch entstehende kompaktere Dateistruktur hat langfristige und vielfältige positive Auswirkungen auf die Leistung.

An dieser Stelle sei noch erwähnt, dass mit DAB auch Teile einer Datei selektiv unterstützt und überwacht (Report „Reads bzw. Writes for internal area“ der Reportgruppe DAB von openSM2) werden können.

11.2.3 CLOSE

Bei geöffneten Dateien ist zu beachten, dass sie immer für bestimmte Gruppen von Anwendern gesperrt sind. Zudem belegen sie Speicher und ihr Abbild auf der Platte ist inkonsistent. Es empfiehlt sich daher, die Datei sofort zu schließen, sobald sie nicht mehr benötigt wird. Es sollten dadurch aber keine unnötigen OPEN-Aufrufe provoziert werden. Bei Banddateien ist mit dem CLOSE ein Rückspulen des Magnetbands verbunden, welches weitere Zugriffe zu dem betreffenden Laufwerk für einige Zeit blockiert. Deshalb ist es auch ratsam, den Aufruf so rechtzeitig zu geben, dass nachfolgende Operationen nicht behindert werden.

Ist die Datei in ihrem Inhalt stark geschrumpft und wird sie längere Zeit klein bleiben, dann sollte sie nach CLOSE mit `/MODIFY-FILE-ATTRIBUTES` (Operand `SPACE=*RELEASE(...)`) bzw. dem Makro `FILE` (mit negativem Parameter `SPACE`) reduziert werden.

11.3 Performantes Laden von Programmen/Produkten

Zunächst werden grob die Vorgänge beim Laden eines Programms/Produkts erläutert. Davon ausgehend werden die Maßnahmen beschrieben, die der Anwender/Produkterstel-ler berücksichtigen sollte, damit die Ladezeit eines Programms/Produkts optimiert werden kann.

Es wird dabei i.d.R. davon ausgegangen, dass die Programme bzw. Module in PLAM-Bibliotheken abgelegt sind. Das Binden der Programme/Module erfolgt deshalb mit BINDER, das Laden mit `/START-EXECUTABLE-PROGRAM`.
Die Ausführungen beschränken sich auf das Arbeiten mit LLMs. Auf das Binden und Laden von Phasen wird nicht explizit eingegangen, obwohl sicher einige der hier aufgeführten Beschleunigungsmaßnahmen ebenfalls angewendet werden können.

11.3.1 Prinzipieller Ablauf beim Binden/Laden eines Programms/Produkts

Schema der beteiligten Instanzen (die zu ladenden LLMs befinden sich in der Bibliothek, die im Ladeaufruf angegeben wird):

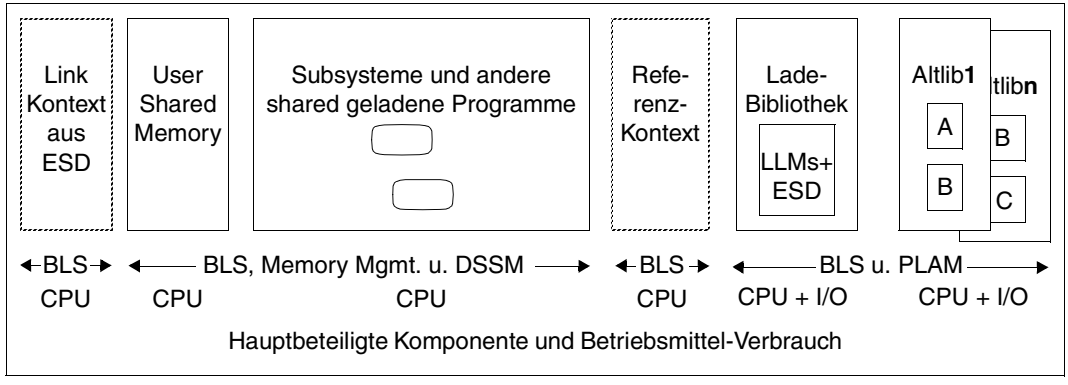

Bild 23: Ablauf beim Binden/Laden eines Programms/Produkts

Die Reihenfolge beim Auflösen (Resolve) der externen Referenzen geht von links nach rechts, d. h. die Instanzen werden in folgender Reihe durchsucht:

a) Link-Kontext (gemäß ESD-Info in LLM); er ist leer, falls es sich um ein „stand alone"-Programm handelt (bei `/START-EXECUTABLE-PROGRAM`)

b) User-Shared-Memory (= Memory-Pools); bei `/START-EXECUTABLE-PROGRAM` können mehrere selektiv angegeben werden (Default: ausgeschaltet)

c) (vorgeladene) DSSM-Subsysteme und andere shared geladene Programme (Default: bei `/START-EXECUTABLE-PROGRAM` eingeschaltet)

d) Referenz-Kontext im Speicher: wird im Laufe des Ladevorgangs dynamisch aufgebaut und zum Befriedigen von Externverweisen verwendet, die im Link-Kontext nicht aufgelöst werden konnten

e) Bibliothek, die im Ladeaufruf angegeben wird

f) Alternative Bibliotheken (AltLibs) nach spezifizierter Reihenfolge

11.3.2 Allgemeine Hinweise zur Beschleunigung des Ladevorganges

- Alle beteiligten PLAM-Bibliotheken sollten so gut wie möglich organisiert sein, d.h.:
  - sie sollten keine überflüssigen LLMs enthalten
  - sie sollten vollständig reorganisiert sein, sodass die erhaltenen LLMs nicht in unnötig viele Extents aufgeteilt sind
  - die Bibliothek selbst sollte aus so wenig Extents wie möglich bestehen
  - die Bibliothek sollte eventuell mit (STD,2) eingerichtet sein

  Mit all diesen Maßnahmen wird die Anzahl der Ein-/Ausgaben reduziert und damit die Laufzeit verbessert; der Effekt ist natürlich abhängig von der Ausgangsstruktur. Eine mit (STD,2) eingerichtete Bibliothek wird um etwa 1 KB pro Element größer sein als die Original-Bibliothek; der Ein-/Ausgabe-Einsparungseffekt wird um so größer sein, je mehr (nicht zu kleine) Elemente die Bibliothek hat. Die Laufzeitverbesserung kann über 10% betragen.

- Beim Laden eines LLM-Objekts sollte immer das Kommando `/START-EXECUTABLE-PROGRAM` verwendet werden. Damit werden effektivere BLS-Suchverfahren angestoßen und etwa 10% der CPU-Zeit eingespart.

- Falls Module mit dem Attribut READ-ONLY versehen sind, sollte ein Slice für Read-Only-Module und ein Slice für Read-Write-Module erzeugt werden. Dies beschleunigt den Ladevorgang sowohl durch geringeren CPU-Bedarf als auch durch Einsparung von Ein-/Ausgaben.

- Die LLM-Größe und damit der PLAM-Aufwand werden reduziert, wenn alle Symbole, die für spätere BINDER-Läufe nicht mehr benötigt werden, invisible gesetzt werden; BINDER-Anweisung:

```
//MODIFY-SYMBOL-VISIBILITY SYMBOL-NAME=...,SYMBOL-TYPE=...,
                           SCOPE=...,VISIBLE=*NO,...
```

- Falls Public-/Private-Slices Anwendung finden, sollte Format 2 zur CPU-Reduzierung von BLS und DSSM verwendet werden
  (siehe BINDER-Anweisung `//SAVE-LLM ... FOR-BS2000-VERSIONS=*FROM-V11`).

  Mit dem Operanden `SUBSYSTEM-ENTRIES` bei der BINDER-Anweisung `//START-LLM-CREATION` kann ein symbolischer Name für die Verknüpfungen zwischen dem Private- und dem Public-Slice angegeben werden. Dieser Name muss auch im DSSM-Katalog definiert sein. (Mit dem alten Format wird für jede Verbindung DSSM aufgerufen.)

- Es ist darauf zu achten, dass in der Parameterdatei von DSSM der Parameter LOGGING **nicht** auf ON gesetzt ist (Default: OFF). ON würde dazu führen, dass beim Laden von Subsystemen DSSM-spezifische Daten protokolliert werden.

- RESOLVE-BY-AUTOLINK aus **mehreren** Bibliotheken:
  Statt der BINDER-Anweisung

  ```
  //RESOLVE-BY-AUTOLINK LIBRARY=A,B,C
  ```

  ist es performanter, wie folgt zu spezifizieren:

  ```
  //RESOLVE-BY-AUTOLINK LIBRARY=A
  //RESOLVE-BY-AUTOLINK LIBRARY=B
  //RESOLVE-BY-AUTOLINK LIBRARY=C
  ```

  Dadurch werden beim dynamischen Nachladen z.B. Verweise, die beim Befriedigen aus Bibliothek B neu entstehen, nur noch in Bibliothek B (und evtl. C) und nicht zuerst in Bibliothek A (und dann in B und evtl. C) gesucht.

11.3.3 Strukturelle Maßnahmen zur Reduzierung des Betriebsmittelbedarfs

Es ist leider nur selten möglich, den Effekt jeder einzelnen der folgenden Maßnahmen genauer zu beziffern. Er hängt zu stark von der Struktur der Ladeobjekte, Subsysteme und Bibliotheken ab. Man kann jedoch i.d.R. davon ausgehen, dass pro Maßnahme ein Mindestgewinn von 10% eintritt.

Bibliotheken reduzieren bzw. deren Inhalt optimieren

- Mischen der Altlibs

  Durch Mischen der Altlibs z.B. in eine einzige Bibliothek (dies könnte sogar die spezifizierte Lade-Bibliothek sein) werden die Suchvorgänge in BLS/PLAM stark reduziert, wodurch z. T. deutlich mehr als 10% an Ein-/Ausgaben und CPU-Zeit eingespart werden.

  Das Mischen ist i.A. nur dann anzuraten, wenn keine namensgleichen CSECTs oder ENTRIES existieren. Falls doch, so muss beim Mischen darauf geachtet werden, dass die „richtigen“ CSECTs oder ENTRIES übernommen werden.

- Module aus Bibliotheken fest einbinden

  Falls sich die Inhalte der Altlibs und der spezifizierten Bibliothek nie bzw. nur selten ändern, empfiehlt es sich eventuell, die Module in das Ladeobjekt fest einzubinden. Dadurch wird der CPU-Bedarf beim Laden verringert. Allerdings wird durch das statische Binden das Ladeobjekt größer und damit i.d.R. mehr Ein-/Ausgaben durchgeführt, was wiederum zur Verlängerung der Laufzeit führt.
  Diese Maßnahme ist demnach günstig, wenn nur kleine Module betroffen sind und wenn die Altlib(s) besonders viele Entries enthalten.

  Wird diese Variante der Performance-Steigerung gewählt, so ist natürlich darauf zu achten, dass der Bindevorgang bei jeder Altlib-Änderung erneut durchzuführen ist.

- Mischform

  Falls sich z.B. der Inhalt von nur einer der beteiligten Altlibs häufig ändert, so empfiehlt es sich eventuell, die Mischform der beiden Methoden zu wählen.

Nachladen aus Shared-Code einschränken

- Kein Nachladen/Binden aus Shared-Code

  Viele Programme benötigen kein Nachladen/Linken aus einem Subsystem/Shared-Programm oder User-Shared-Memory. Diese Programme sollten wie folgt gestartet werden:

  ```
  /START-EXECUTABLE-PROGRAM ...,
     DBL-PARAMETERS=*PARAMETERS(RESOLUTION=*PARAMETERS(SHARE-SCOPE=*NONE)),
     ...
  ```

  Dadurch wird verhindert, dass DSSM von BLS aufgerufen wird, um die Subsysteme nach dem Entry zu durchsuchen, und es ergibt sich eine z. T. erhebliche Einsparung an CPU-Zeit.

- Nur aus System-Memory nachladen

  Dieser Fall ist der Default-Fall. Es gibt keine Möglichkeit, die DSSM-Suche nach dem Entry auf bestimmte Subsysteme oder nur auf Shared-Programme zu beschränken.

- Nur aus User-Shared-Memory nachladen

  Bei `/START-EXECUTABLE-PROGRAM` kann mit dem Parameter

  ```
  DBL-PARAMETERS=*PARAMETERS(RESOLUTION=*PARAMETERS(
                                          SHARE-SCOPE=*MEMORY-POOL(...)))
  ```

  die Beschränkung auf User-Shared-Memory definieren. Es ist dabei zusätzlich möglich, sich auf ausgewählte Memory-Pools zu beschränken.

- Vorladen des User-Shared-Memory

  Sofern möglich, sollten alle shareable Teile der benutzten Anwendungen vorgeladen werden (Beispiel: FOR1-RTS). Dadurch werden sie nur einmal geladen, und bei jedem weiteren Ladevorgang muss nur noch die (aufwandsarme) Verknüpfung durchgeführt werden. Damit können meist deutlich mehr als 10% der Ein-/Ausgaben und des CPU-Bedarfes eingespart werden.

ESD-Information eliminieren

- Vollkommene Eliminierung

  Diese Maßnahme ist nur für „standalone“-Programme durchführbar. Dies sind LLMs, die von anderen Programmen nicht aufgerufen werden und die vollständig vorgebunden sind. Für sie sollte zur Beschleunigung des Ladevorgangs die ESD- und sonstigen BLS-Informationstabellen durch einen entsprechenden BINDER-Aufruf eliminiert werden. Dazu ist der BINDER wie folgt aufzurufen:

```
/START-BINDER
//START-LLM-UPDATE LIB=<orig-biblio>,ELEMENT=<elem-name>
//SAVE-LLM LIB=<neue lade-biblio>,TEST-SUPPORT=*NO,MAP=*NO,
           SYMBOL-DICTIONARY=*NO,LOGICAL-STRUCTURE=*NO,
           RELOCATION-DATA=*NO
//END
```

  Durch diese Parameterwahl werden nur die zum Laden notwendigen BLS-Strukturen eines einfachen Programmes erzeugt. Damit wird das Objekt kleiner. Beim Laden des Programmes werden somit CPU und weitere Ein-/Ausgaben eingespart. Alle für die Bearbeitung notwendigen Informationen sind danach nicht mehr vorhanden.
  Das bedeutet:

  – Diese Parameter können nicht für Ladeobjekte, die in mehrere Slices aufgeteilt sind, verwendet werden.
  – Mit solch einem Objekt können keine LLM-Updates durchgeführt werden.
  – Relocatable Objekte (z.B. als Teil eines Runtime-Systems) können nicht erzeugt werden.

  Die (zusätzliche) Parameter-Einstellung `REQUIRED-COMPRESSION=*YES` sollte nicht gewählt werden, da dadurch zwar max. 10% der Ein-/Ausgaben eingespart, aber etwa 40% mehr CPU benötigt werden.

- Teilweise Eliminierung

  Beim Mischen von LLMs oder Sub-LLMs in einen Großmodul mit einer einzigen CSECT sollte bei der BINDER-Anweisung `//MERGE-MODULES` angegeben werden, welche ESD-Informationen im Extern-Adressbuch bleiben sollen. Damit kann der BLS-Aufwand beim Laden stark reduziert werden.

11.3.4 Beschleunigung des Ladevorganges von C-Programmen

Das Laden von C-Programmen wird beschleunigt, wenn die wenigen nicht vorladbaren Module aus dem C-RTS zum übersetzten Programm dazugebunden werden. Dies wird durch folgende zusätzliche BINDER-Anweisung erreicht:

```
//RESOLVE-BY-AUTOLINK LIB=<Partial-Bind-Lib>
```

Die <Partial-Bind-Lib> wird unter dem Namen SYSLNK.CRTE.PARTIAL-BIND installiert. Außerdem ist das Ausblenden von Extern-Namen zur Unterdrückung von DUPLICATE SYMBOLS notwendig:

```
//MODIFY-SYMBOL-VISIBILITY SYMBOL-NAME=*ALL,VISIBLE=*NO
```

Durch beide Anweisungen werden die CPU-Zeit und vor allem die Laufzeit beim Laden von C-Programmen stark reduziert, wobei das Ladeobjekt nur wenige Seiten (ca. 18) größer als das übersetzte Programm ist.

Damit die CRTE in den Shared-Code geladen wird, müssen die Subsysteme CRTEC und CRTECOM geladen sein.

11.3.5 Nutzung von DAB

Falls das gebundene Objekt und/oder die benutzten Bibliotheken sehr groß sind und deshalb eine hohe Anzahl von Ein-/Ausgaben beim Laden ausgeführt werden muss, sollte der Einsatz von DAB (Disk Access Buffer) geprüft werden.

Mit DAB können bei häufig referenzierten Dateien die Ein-/Ausgaben so stark reduziert werden, dass im Extremfall die Laufzeit nur noch vom CPU-Bedarf abhängt.

Für das Ladeobjekt ist dabei ein Cache-Bereich zu wählen, der genauso groß wie das Objekt ist. Dies ist besonders einfach, wenn das Objekt das einzige Element der Bibliothek ist. Dann wird mit

```
/START-DAB-CACHING AREA=*FILE(FILE-AREA=<biblio>),CACHE-SIZE=*BY-FILE
```

ein Hauptspeicher-Bereich von der Größe der Bibliothek reserviert. Dieser wird beim ersten Laden des Objektes gefüllt, sodass bei allen folgenden Ladevorgängen keine zeitintensiven Ein-/Ausgaben mehr notwendig sind.

Die Cache-Bereiche für die Bibliotheken können i.d.R. kleiner gewählt werden als die Gesamtgröße der Bibliotheken, da meist nicht alle enthaltenen Module nachgeladen werden. Dazu ist bei /START-DAB-CACHING die Cache-Größe (in KB oder MB) explizit anzugeben. Mit openSM2 oder /SHOW-DAB-CACHING kann die Cache-Trefferrate jedes Cache-Bereichs überwacht werden. Die Hit-Rate sollte mindestens 80% betragen. Ist sie niedriger, muss der Bereich vergrößert werden.

12 Anhang

12.1 Richtwerte für die BS2000/OSD-Server

In den folgenden Tabellen sind einige Leistungsdaten und Richtwerte für S-, SX und SQ-Server zusammengefasst. Die Empfehlungen gelten für einen typischen TP-Betrieb mit üblicher Hintergrundlast.

- Relativer Performance Faktor RPF und Anzahl der CPUs.
- Typischer Hauptspeicherausbau.
  Der tatsächliche Hauptspeicherbedarf hängt ab von der Last, mit der der Server betrieben wird. TP- und Dialog-Lasten haben üblicherweise einen deutlich größeren Hauptspeicherbedarf als Batch-Lasten.

  Auf SX-Servern und auf dem Business Server SQ100 wird der Hauptspeicher zwischen BS2000/OSD und Dom0/X2000 (I/O-Prozessor) aufgeteilt. Eine Empfehlung für Ausbau und Aufteilung des Hauptspeichers zeigen die entsprechenden Tabellen.
  Hinweise darauf, wann mehr als der dort empfohlene Hauptspeicher eingesetzt werden soll, finden Sie im Abschnitt „Hauptspeicher auf SX-Servern“ auf Seite 38 und im Abschnitt „Hauptspeicher auf SQ-Servern“ auf Seite 39.
- Maximal empfohlene Anzahl der DVS-Ein-/Ausgaben.
  Ein IT-System wird wirtschaftlich genutzt, wenn eine ausgewogene Mischung von rechenintensiven und Ein-/Ausgabe-intensiven Programmen abläuft. Die maximal empfohlene Anzahl von DVS-Ein-/Ausgaben pro Sekunde stellt keine technische Obergrenze dar, sondern gewährleistet, dass nur ein bestimmter Teil der CPU-Leistung für die Durchführung von Ein-/Ausgaben verbraucht wird. Eine Überschreitung ist ohne weiteres möglich, sofern Engpässe bei den Peripherie-Geräten vermieden werden.
- Maximal empfohlene Anzahl der Paging-Ein-/Ausgaben.
  Die für den Transaktions- bzw. Dialogbetrieb angegebenen Werte für die maximal empfohlene Paging-Rate stellen sicher, dass nur ein gewisser Teil der CPU-Leistung für Paging verbraucht wird. Um zeitliche Verzögerungen durch Paging (besonders bei Transaktionsbetrieb) zu vermeiden, sollte angesichts des verfügbaren Hauptspeichers die Unterschreitung der genannten Werte angestrebt werden.

- Maximal empfohlene Anzahl SVCs in TU.
  Wenn die maximale Anzahl SVC-Aufrufe pro Sekunde erreicht wird, dann beträgt der Aufwand für die Unterbrechungsanalyse und Abschlussbehandlung der Systemroutine (also nicht der Aufwand für die Systemroutine selbst) ca. 5% der CPU-Zeit.
- Maximale empfohlene Anzahl VM2000-Gastsysteme für SX-Server, siehe Seite 360.
  Diese Obergrenze bezieht sich nur auf den Hauptspeicherbedarf ohne Berücksichtigung des CPU-Bedarfs dieser Gastsysteme. Die Anzahl von Gastsystemen mit Produktionslast ist in der Regel niedriger anzusetzen (siehe Abschnitt „Anzahl und Multiprozessorgrad der VMs“ auf Seite 151).

Richtwerte für S-Server

S-Server		RPF	Anzahl CPUs	Typische Hauptspeichergröße in GB	Maximal empfohlene Anzahl (pro Sekunde)			
					DVS-Ein-/Ausgaben	Paging-Ein-/Ausgaben		SVCs in TU
						TP-Betrieb	Dialogbetrieb	
S120	- B	56	1	0,5	1400	70	210	2800
	- C	79	1	0,5	1800	80	250	3900
	- D	95	1	1,0	2100	90	270	4700
	- E	110	1	1,0	2400	100	300	5500
S140	- 10B	156	1	1	3200	100	300	7800
	- 10C	190	1	1	3800	100	300	9500
	- 20A	240	2	2	4600	100	300	12000
	- 20B	300	2	2	5500	100	300	15000
	- 20C	360	2	2	6500	100	300	18000
	- 30C	510	3	4	8600	100	300	25500
	- 40C	650	4	4	10400	100	300	32500
S145	- 10B	231	1	2	4500	100	300	11500
	- 10C	264	1	2	5000	100	300	13200
	- 10D	300	1	2	5500	100	300	15000
	- 20A	400	2	3	7000	100	300	20000
	- 20D	540	2	4	9000	100	300	27000
	- 30D	765	3	6	12000	100	300	38000
S155	- 10A	204	1	2	4000	100	300	10000
	- 10B	244	1	4	4500	100	300	12000
	- 10C	283	1	4	5500	100	300	14000
	- 10D	320	1	4	6000	100	300	16000
	- 20A	430	2	4	7500	100	300	22000
	- 20D	575	2	6	10000	100	300	29000
	- 30D	820	3	6	13000	100	300	41000

Tabelle 1: Richtwerte für S-Server (Teil 1 von 3)

S-Server		RPF	Anzahl CPUs	Typische Hauptspeichergröße in GB	Maximal empfohlene Anzahl (pro Sekunde)			
					DVS-Ein-/Ausgaben	Paging-Ein-/Ausgaben		SVCs in TU
						TP-Betrieb	Dialogbetrieb	
S165	- 1RB	160	1	2	3200	100	300	8000
	- 10A	225	1	2	4500	100	300	11000
	- 10B	270	1	4	5100	100	300	13500
	- 10C	310	1	4	5600	100	300	15000
	- 10D	350	1	4	6000	100	300	17000
	- 20A	400	2	4	6800	100	300	20000
	- 20B	490	2	6	8300	100	300	24000
	- 20D	640	2	6	10000	100	300	32000
	- 30D	910	3	8	14000	100	300	45000
S170	- 30	510	3	4	8600	100	300	25500
	- 40	650	4	4	10400	100	300	32500
	- 60	960	6	6	14300	100	300	48000
	- 65	960	6	6	14300	100	300	48000
	- 80	1260	8	8	17800	100	300	63000
	- 100	1490	10	8	20400	100	300	74000
	- 120	1720	12	12	23000	100	300	86000
	- 140	1920	14	12	24500	100	300	96000
S180	- 30	765	3	6	12000	100	300	38000
	- 40	990	4	6	14800	100	300	50000
	- 60	1350	6	8	19000	100	300	67500
	- 65	1350	6	8	19000	100	300	67500
	- 80	1710	8	12	23000	100	300	86000
	- 100	2040	10	12	26000	100	300	102000
	- 120	2340	12	16	28500	100	300	117000
	- 140	2640	14	16	31000	100	300	130000

Tabelle 1: Richtwerte für S-Server (Teil 2 von 3)

S-Server		RPF	Anzahl CPUs	Typische Hauptspeichergröße in GB	Maximal empfohlene Anzahl (pro Sekunde)			
					DVS-Ein-/Ausgaben	Paging-Ein-/Ausgaben		SVCs in TU
						TP-Betrieb	Dialogbetrieb	
S190	- 30	820	3	12	13000	100	300	41000
	- 40	1060	4	12	16000	100	300	53000
	- 65	1450	6	16	20000	100	300	72000
	- 80	1830	8	16	25000	100	300	92000
	- 100	2190	10	16	28000	100	300	110000
	- 120	2510	12	20	31000	100	300	125000
	- 140	2830	14	20	33000	100	300	140000
	- 150	3000	15	20	35000	100	300	145000
S200	- 20	860	2	8	13000	100	300	43000
	- 30	1170	3	12	17000	100	300	58000
	- 40	1520	4	16	21000	100	300	75000
	- 60	2050	6	16	26000	100	300	102000
	- 80	2600	8	20	31000	100	300	130000
	- 100	3100	10	24	37000	100	300	155000
	- 120	3600	12	24	43000	100	300	180000
	- 140	4100	14	32	45000	100	300	205000
	- 150	4300	15	32	47000	100	300	215000

Tabelle 1: Richtwerte für S-Server (Teil 3 von 3)

Richtwerte für SX-Server

SX-Server		RPF	Anzahl CPUs	Typische Hauptspeichergröße in GB	Maximal empfohlene Anzahl (pro Sekunde)			
					DVS-Ein-/Ausgaben	Paging-Ein-/Ausgaben		SVCs in TU
						TP-Betrieb	Dialogbetrieb	
SX100	-B1	12	1	4	850	7	21	650
	-B2	20	1	4	1000	9	28	1000
	-B3	30	1	4	1200	13	40	1500
	-C1	12	1	4	850	7	21	600
	-C2	20	1	4	1000	9	28	1000
	-C3	30	1	4	1200	13	40	1500
	-D1	12	1	4	850	7	21	600
	-D2	20	1	4	1000	9	28	1000
	-D3	30	1	8	1200	13	40	1500
SX140	-10A	42	1	4	1000	14	42	2100
	-10B	58	1	4	1400	17	50	2800
	-10C	75	1	4	1700	20	60	3700
	-20A	94	2	4	2100	23	70	4600
	-20B	113	2	4	2500	26	80	5600
	-20C	133	2	4	2900	29	90	6500
	-30C	185	3	8	3700	36	110	8900
	-40C	235	4	8	4300	42	130	11100
	-50C	280	5	8	5100	48	150	13500
	-60C	320	6	12	6000	54	160	15600
SX150	-10A	42	1	8	1000	55	170	2100
	-10B	75	1	8	1700	80	250	3700
	-10C	105	1	8	2300	100	300	5200
	-20A	140	2	8	2800	100	300	7000
	-20C	180	2	8	3600	100	300	9000
	-30C	250	3	12	4700	100	300	12500
	-40C	320	4	12	6000	100	300	16000
	-50C	380	5	12	6700	100	300	19000
	-60C	430	6	16	7500	100	300	21500

Tabelle 2: Richtwerte für SX-Server (Teil 1 von 2)

SX-Server		RPF	Anzahl CPUs	Typische Hauptspeichergröße in GB	Maximal empfohlene Anzahl (pro Sekunde)			
					DVS-Ein-/Ausgaben	Paging-Ein-/Ausgaben		SVCs in TU
						TP-Betrieb	Dialogbetrieb	
SX160	-10A	42	1	8	1000	55	170	2100
	-10B	75	1	8	1700	80	250	3700
	-10C	105	1	8	2300	100	300	5200
	-20A	150	2	12	3000	100	300	7500
	-20C	200	2	12	3800	100	300	10000
	-30C	280	3	16	5200	100	300	14000
	-40C	370	4	16	6500	100	300	18500
	-50C	450	5	16	7700	100	300	22500
	-60C	530	6	24	9000	100	300	26500

Tabelle 2: Richtwerte für SX-Server (Teil 2 von 2)

SX-Server	Hauptspeicher-ausbau (GB)	Anteil X2000-Hauptspeicher (GB)	Max. empfohlene Anzahl Gastsysteme (VM2000-Betrieb)
SX100-B SX100-C	4	1	4
SX100-D1 SX100-D2	4	1,5	4
SX100-D3	8	2	4
SX140-10 SX140-20	4	1	4
SX140-30	8	2	6
SX140-40 SX140-50	8	2	8
SX140-60	12	2	10
SX150-10 SX150-20	8	2	4
SX150-30	12	2	6
SX150-40 SX150-50	12	2	8
SX150-60	16	3	10
SX160-10	8	2	4
SX160-20	12	3	4
SX160-30	16	4	6
SX160-40 SX160-50	16	4	8
SX160-60	24	6	10

Tabelle 3: SX-Server: Hauptspeicher-Aufteilung und VM2000-Betrieb

Richtwerte für SQ-Server

SQ-Server	RPF	Anzahl CPUs	Typische Hauptspeichergröße in GB	Maximal empfohlene Anzahl (pro Sekunde)			
				DVS-Ein-/Ausgaben	Paging-Ein-/Ausgaben		SVCs in TU
					TP-Betrieb	Dialogbetrieb	
SQ100 -10A	12	1	8	850	7	21	600
-10B	20	1	8	1000	9	28	1000
-10C	35	1	8	1200	13	40	1750
-10D	65	1	12	1500	70	250	3000
-20A	85	2	12	2000	100	300	4250
-20D	110	2	12	2400	100	300	5500
-30D	155	3	16	3200	100	300	7750
-40D	200	4	16	3800	100	300	10000

Tabelle 4: Richtwerte für SQ-Server

SQ-Server	Hauptspeicherausbau (GB)	Anteil Dom0/X2000-Hauptspeicher (GB)
SQ100-10A SQ100-10B SQ100-10C	8	2,4
SQ100-10D SQ100-20A SQ100-20D	12	3,6
SQ100-30D SQ100-40D	16	4,8

Tabelle 5: SQ-Server: Hauptspeicher-Aufteilung und VM2000-Betrieb

12.2 Performance-relevante Systemparameter

Mit Hilfe der BS2000/OSD-Systemparameter (die im Parametersatz SYSOPT-CLASS2 der Parameterdatei `SYSPAR.BS2.version` definiert sind) kann das Systemverhalten den jeweiligen Erfordernissen angepasst werden.

In diesem Abschnitt werden die folgenden, performance-relevanten Systemparameter beschrieben:

BMTNUM (Seite 363)
CATBUFR (Seite 363)
CONSDDE7 (Seite 364)
DEFLUID (Seite 365)
DESTLEV (Seite 365)
DMPRALL (Seite 366)
DMSCALL (Seite 366)
DMMAXSC (Seite 366)
EACTETYP (Seite 369)
EAMMEM (Seite 370)
EAMMIN (Seite 370)
EAMSEC (Seite 370)
EAMSIZ (Seite 370)
ETMFXLOW (Seite 371)
JTABSMEM (Seite 371)
JTSTDMEM (Seite 371)
JTMAXMEM (Seite 371)
L4MSG (Seite 369)
L4SPDEF (Seite 372)
MSGCENTL (Seite 369)
MSGCENTN (Seite 369)
MSGDLAM (Seite 369)
MSGFILii (Seite 369)
MSGNOFL (Seite 369)
SSMAPRI (Seite 372)
SSMASEC (Seite 372)
TEMPFILE (Seite 373)

Die vollständige Liste der Systemparameter und ihre detaillierte Beschreibung finden Sie im Anhang des Handbuchs „Einführung in die Systembetreuung“ [11].

BMTNUM und CATBUFR

Verwaltung und Zugriffe zum Dateikatalog TSOSCAT werden intern durch die Katalogverwaltung (Catalog Management System, CMS) ausgeführt. Funktionsbeschreibung und weitere Anregungen für das Tuning werden im Abschnitt „Einrichten von Systemdateien“ auf Seite 174 behandelt.

Die Systemparameter BMTNUM und CATBUFR sollten immer zusammen betrachtet werden. Bei der Entscheidung, welche Werte diesen Parametern zugeordnet werden, ist zu berücksichtigen, mit wie vielen Pubsets das System betrieben werden soll (Einfluss siehe bei CATBUFR).

Parametername	Werte-Bereich	STD-Wert
BMTNUM	0 ... 255	6

Der Parameter BMTNUM legt die Anzahl der Ein-/Ausgabe-Puffer und Pufferverwaltungstabellen (Buffer Management Tables, BMT) für die Katalogverwaltung (CMS) fest. Diese Anzahl Puffer wird einmal für jeden Pubset und einmal global für alle Private-Volumes angelegt.

Jeder Block des TSOSCAT kann max. 13 Datei- oder 18 JV-Einträge enthalten. Zu jedem CMS-Ein-/Ausgabe-Puffer (4096 Byte) wird eine Tabelle (BMT) angelegt (ca. 178 Bytes). Über sie wird der aktuelle Zustand des Blocks im Puffer verwaltet.

Der Standardwert für BMTNUM ist 6.
Jede Erhöhung vergrößert auch die Wahrscheinlichkeit, dass ein gesuchter Datei- oder JV-Eintrag vom CMS ohne Durchführung einer physikalischen Eingabe-Operation gefunden wird. Besonders positiv macht sich diese Strategie bemerkbar, wenn häufig auf benachbart abgelegte Katalogeinträge und somit auf ein und denselben Katalogblock zugegriffen wird.

Parametername	Werte-Bereich	STD-Wert
CATBUFR	N/Y	N

Durch Belegen des Parameters CATBUFR mit dem Wert Y werden die CMS-Puffer und die BMTs resident angelegt (im Klasse-3-Speicher).
Mit dem Wert N (Standard) werden sie seitenwechselbar angelegt (im Klasse-4-Speicher).

Die pubset-spezifische Einstellung der Anzahl CMS-Puffer und deren Speicherklasse erfolgt mit Hilfe der Kommandos

```
/ADD-MASTER-CATALOG-ENTRY
/MODIFY-MASTER-CATALOG-ENTRY
/IMPORT-PUBSET
```

und den Operanden `NUMBER-OF-BUFFERS` und `RESIDENT-BUFFERS`.

Dabei wird in folgender Reihenfolge nach definierten Werten gesucht:

1. Explizite Parameterangabe bei /IMPORT-PUBSET
2. Angabe bei /ADD-MASTER-CATALOG-ENTRY bzw. /MODIFY-MASTER-CATALOG-ENTRY
3. Angabe über die Systemparameter BMTNUM und CATBUFR

Werden keine Privatplatten eingesetzt, so kann mit BMTNUM=0 die Pufferbelegung für Privatplatten verhindert werden. Mit /MODIFY-MASTER-CATALOG-ENTRY (für Home- und Paging-Pubset) bzw. /IMPORT-PUBSET muss dann die Anzahl der CMS-Puffer und deren Speicherklasse spezifiziert werden.

Die Größe des Adressraumbedarfs pro Pubset oder der Private-Volumes für die Puffer der Katalogverwaltung erhält man durch folgende Formel:

```
CMS-Puffer (Byte) = (4096 + x) * Anzahl Puffer + 384
```

x= 178 für Pubsets
200 für Private-Volumes

Werden z.B. bei kleineren Servern viele speicherresidente Puffer angelegt, so werden zwar die Katalogoperationen schneller, aber eine eventuell erhöhte Paging-Rate kann diesen Vorteil ausgleichen. Bei starker Katalogbeanspruchung ist der Einsatz des Produkts SCA (Speed Catalog Access) unerlässlich.

CONSDDE7

Parametername	Werte-Bereich	STD-Wert
CONSDDE7	N/Y	N

Der Systemparameter CONSDDE7 dient zur Reduzierung des Meldungsumfangs auf der Bedienstation.

Die Systemmeldung DMSODE7 SAM FILE CLOSED wird bei Y auf SYSOUT und Bedienstation, bei N nur auf SYSOUT ausgegeben.

Wenn für SPOOL ein Magnetband als Ausgabegerät zugewiesen ist, erscheint diese Meldung am Ende jeder SPOOL-Ausgabe. Standardwert ist N.

DEFLUID

Parametername	Werte-Bereich	STD-Wert
DEFLUID	:catid:$userid	$TSOS

In den Kommandos /LOAD- bzw. /START-(EXECUTABLE-)PROGRAM, /CALL-PROCEDURE, /ENTER-PROCEDURE und /ENTER-JOB kann beim Operanden FROM-FILE auch dann die Angabe der Katalog- und Benutzerkennung entfallen, wenn die benötigte Datei nicht unter der Kennung des Aufrufers katalogisiert ist.

In einem zweiten Suchlauf (Secondary-Read) wird in der Kennung gesucht, die bei diesem Systemparameter angegeben ist.

Die Möglichkeit, hier eine andere Kennung als den Standardwert $TSOS anzugeben, dient zur Entlastung der Kennung TSOS. Es wird empfohlen, alle vom Rechenzentrum den Anwendern zur Verfügung gestellten Programme und Verfahren unter einer eigenen Bibliotheks-Benutzerkennung zu speichern, und diese dem System mit der Option DEFLUID bekanntzugeben.

DESTLEV

Parametername	Werte-Bereich	STD-Wert
DESTLEV	0/1/4/5/6	0

Mit DESTLEV wird festgelegt, ob Datei-Extents beim Freigeben vom System (/DELETE-FILE oder /MODIFY-FILE-ATTRIBUTES mit Speicherplatzfreigabe) mit binären Nullen überschrieben werden sollen.

Bei großen Dateien kann dieser Vorgang sehr lange dauern (im Minuten-Bereich).

DMPRALL, DMSCALL, DMMAXSC

Diese drei Systemparameter sind aufeinander abgestimmt festzulegen. Sie dienen als Voreinstellungen für die Platzzuweisung beim Einrichten und Erweitern von Dateien. Die Werte gelten für alle Private-Volumes. Für Pubsets gelten sie nur, wenn im MRSCAT-Eintrag des Pubsets nichts anderes festgelegt wurde. Zusätzlich wird die beim Einrichten des Pubsets mit SIR angegebene Allocation-Unit abhängig vom Datenformat (K, NK2, NK4) berücksichtigt.

In folgender Reihenfolge wird nach definierten Werten gesucht:

1. Direkte Angabe in den Kommandos `/CREATE-FILE` oder `/MODIFY-FILE-ATTRIBUTES`
2. Eintrag im MRSCAT
   - Erfolgt die Angabe mit `/MODIFY-MASTER-CATALOG-ENTRY` (Operand `ALLOCATION`), so wird die Änderung erst nach dem nächsten Importieren des Pubsets gültig.
   - Bei Verwendung von `/MODIFY-PUBSET-SPACE-DEFAULTS` (Operand `PRIMARY-ALLOCATION` / `SECONDARY-ALLOCATION` / `MAX-ALLOC`) wird die Vereinbarung sofort gültig.
3. Angabe über Systemparameter

Wenn die so ermittelten Werte kein Vielfaches der beim Einrichten des Pubsets mit SIR festgelegten Allocation Unit sind, dann werden sie auf das nächste Vielfache aufgerundet.

Primärzuweisung

Parametername	Werte-Bereich	STD-Wert
DMPRALL	3...65535	3

Primärzuweisung für eine Datei in PAM-Blöcken, wenn bei `/CREATE-FILE` oder `/MODIFY-FILE-ATTRIBUTES` (bzw. im FILE-Makro) der Operand `SPACE` nicht versorgt wurde.

Sekundärzuweisung

Parametername	Werte-Bereich	STD-Wert
DMSCALL	3...65535	3

Sekundärzuweisung für eine Datei in PAM-Blöcken, wenn bei `/CREATE-FILE` oder `/MODIFY-FILE-ATTRIBUTES` (bzw. im FILE-Makro) diese im Operand `SPACE` nicht versorgt wurde.

Nach jeder Dateierweiterung wird der Betrag des Zuwachses verdoppelt gegenüber dem Wert bei der vorherigen Erweiterung. Secondary-Allocation (SA) bei (i+1)-ter Erweiterung gleich zweimal Secondary-Allocation bei i-ter Erweiterung: `SA(i+1) = 2 * SA(i)`

Diese Formel wird so lange angewendet, bis der doppelte Wert der aktuellen Sekundärzuweisung den Wert DMMAXSC überschreitet. Danach gilt: `SA(i+1) = SA(i)`

Maximalwert

Parametername	Werte-Bereich	STD-Wert
DMMAXSC	3...65535	48

Wenn der doppelte Wert der aktuellen Sekundärallokierung den Wert von DMMAXSC überschreitet, dann wird der Wert für die Sekundärallokierung nicht mehr verändert.

Beispiel

Dateierweiterungen mit den Werten: DMPRALL 15, DMSCALL 3, DMMAXSC 48.
In diesem Beispiel könnte DMMAXSC jeden Wert zwischen 48 und 96 enthalten, ohne dass sich das Verhalten ändert.

15	+	3	=	18	(1. Dateierweiterung)
18	+	6	=	24	(2. Dateierweiterung)
24	+	12	=	36	(3. Dateierweiterung)
36	+	24	=	60	(4. Dateierweiterung)
60	+	48	=	108	(5. Dateierweiterung)
108	+	48	=	156	(6. Dateierweiterung, keine Veränderung der Sekundärallokierung, da der Wert dann größer wäre als DMMAXSC)

Beim Einrichten einer Datei auf Platte oder Verändern ihrer Größe ist DVS-intern der kleinste Betrag, um den eine Änderung wirksam wird, eine Allocation-Unit.

Die kleinste Allocation-Unit beträgt für

Private-Volumes: 3 PAM-Blöcke

Pubsets: 3 PAM-Blöcke (K- und NK2-Format)
4 PAM-Blöcke (NK4-Format)

Jede dynamische Dateierweiterung führt zu einer Reihe von Verwaltungs-Ein-/Ausgaben im System (Aktualisierung der Einträge in der Benutzerkennung, im Dateikatalog, im F1-Kennsatz bei Private-Volumes) und verursacht somit einen beträchtlichen Systemaufwand. Um diesen Aufwand zu minimieren, sollte der DMSCALL-Parameter auf mindestens vier Allocation-Units gesetzt werden.

Um die Anzahl der dynamischen Dateierweiterungen zu reduzieren (bzw. zu vermeiden), steht jedem Anwender bei `/CREATE-FILE` und `/MODIFY-FILE-ATTRIBUTES` der Operand `SPACE=*RELATIVE(PRIMARY-ALLOCATION=xx,SECONDARY-ALLOCATION=yy)` zur Verfügung.

Jeder Anwender sollte grundsätzlich versuchen, die Datei schon bei der Erstellung durch eine entsprechende Primärzuweisung in der voraussichtlichen Endgröße einzurichten.

Beispiel

Ein Programm schreibt mit dem PAM-Makroaufruf sequenziell 456 Blöcke. Mit dem AINF-Makroaufruf wird die Anzahl der Ein-/Ausgabe-Operationen ermittelt.

/CREATE-FILE ...,SPACE=REL		**Anzahl phys.**	**Anzahl Extents lt.**
(PRI-ALLOC=...,	SEC-ALLOC=...)	**Ein-/Ausgaben lt. AINF**	/SHOW-FILE-ATTR
3	3	480	20
6	6	476	18
30	30	467	9
192	192	459	3
456	30	456	1

Abhängig von der jeweiligen Plattenbelegung können die Ergebnisse etwas streuen.

EACTETYP, L4MSG, MSGCENTL, MSGCENTN, MSGDLAM, MSGFILii, MSGNOFL

Diese Parameter gehören zusammen:

Parametername	Werte-Bereich	STD-Wert	Bedeutung
EACTETYP	0/1/2/3	0	Legt fest, welche der folgenden Meldungen über die Bedienstation ausgegeben werden sollen: `BLS0500`, `BLS0517`, `BLS0519`, `BLS0523`, `BLS0524`, `BLS0526`, `BLS0539`, `BLS0551`, `BLS0552`. 0 keine der Meldungen 1 nur die Meldung `BLS0519` 2 alle oben genannten Meldungen 3 alle Meldungen außer `BLS0519`
L4MSG	0/1	0	Steuert die Ausgabe der Meldung `EXC044E "ACCEPT ALLOCATION REQUEST..."`. 0 Meldung wird nicht ausgegeben 1 Meldung wird ausgegeben
MSGCENTL	20...n	200	Legt die Länge eines Eintrags im Klasse-4-Speicher für die Meldungsbearbeitung fest. Der Wert muss ein Vielfaches von 4 sein. In diesem Bereich des Klasse-4-Speichers werden die zuletzt und am häufigsten benutzten Meldungen zwischengespeichert, um Dateizugriffe zu sparen.
MSGCENTN	0..n	32	Legt die Anzahl von Einträgen im Klasse-4-Speicher (s.o.) für die Meldungsbearbeitung fest. *Hinweis*: Der Bedarf an Klasse-4-Speicher kann durch Multiplizieren der Werte von MSGCENTL und MSGCENTN berechnet werden.
MSGDLAM	0...99	0	Anzahl der Meldungsdateien, die über DLAM verarbeitet werden sollen.
MSGFIL01 MSGFIL02 MSGFIL03 MSGFIL04 : MSGFIL15 *)	dateiname(n)		Anzahl und Dateinamen der Meldungs-Ausgabedateien. Für die Parameter MSGFIL01 und MSGFIL02 gilt folgende Standardeinstellung: MSGFIL01: `SYSMES.BS2CP.version` MSGFIL02: `SYSMES.EKP.01` Für die Parameter MSGFIL03 bis MSGFIL15 gibt es keine Standardnamen, d.h. diese Dateien werden nicht eingerichtet. Der Dateiname muss vollqualifiziert sein und kann nur mit der Benutzerkennung $TSOS katalogisiert werden.
MSGNOFL *)	0...15	2	Anzahl der Meldungsdateien, die durch die Parameter MSGFILxx spezifiziert wurden.

*) für Details siehe Abschnitt „Meldungsdateien“ auf Seite 187

EAMMEM, EAMMIN, EAMSEC, EAMSIZ

Parametername	Werte-Bereich	STD-Wert
EAMMEM	0...2730	0
EAMMIN	4...64512	3000
EAMSEC	1...64512	200
EAMSIZ	4...64512	64512

Mit diesen Parametern wird die Größe der Datei SYSEAM definiert. Diese Parameter gelten für alle Dateien :catid:SYSEAM, wenn sie auf mehreren Pubsets eingerichtet sind und im MRSCAT-Eintrag pro Pubset nichts anderes festgelegt ist. Zusätzlich wird die beim Einrichten des Pubsets mit SIR angegebene Allocation-Unit abhängig vom Datenformat (K, NK2, NK4) berücksichtigt.

Die Datei SYSEAM wird in EAM-Allocation-Units verwaltet. Bei einer DMS-Allocation-Unit von 3 PAM-Seiten ist die EAM-Allocation-Unit ebenfalls 3 PAM-Seiten; bei allen anderen DMS-Allocation-Units ist die EAM-Allocation-Unit 4 PAM-Seiten. Mit dem Wert EAMMIN wird die Minimalgröße festgelegt. Bei Bedarf wird sie um den Wert EAMSEC (Anzahl in EAM-Allocation-Units) erweitert, bis die Maximalgröße von 64.512 EAM-Allocation-Units erreicht ist. Sollte die Datei SYSEAM schrumpfen (z.B. bei /DELETE-SYSTEM-FILE SYSTEM-FILE=*OMF, /EXIT-JOB u.a.), wird sie in Einheiten von 8 Allocation-Units verringert, jedoch nicht unter den Wert von EAMMIN.

Der Wert von EAMMIN ist so einzustellen, dass im Normalbetrieb 80% aller Anforderungen zum Speichern von Blöcken in der Systemdatei SYSEAM befriedigt werden können, ohne dass eine Erweiterung der Datei notwendig wird. Als Erfahrungswert für die Ersterstellung ist eine Größe von 4000 Allocation-Units angezeigt.

Wird der Wert für EAMMIN zu klein gewählt, so treten als Folge eine höhere Systembelastung durch viele dynamische Dateierweiterungen und ein unkontrolliertes Wachsen der Datei SYSEAM ein.

Durch geeignete Wahl von EAMMIN und EAMSEC bzw. des Operanden EAM (MINIMAL-SIZE, SECONDARY-ALLOCATION) bei /ADD-MASTER-CATALOG-ENTRY und /MODIFY-MASTER-CATALOG-ENTRY kann das Pulsieren der Dateigröße von SYSEAM auf ein Minimum beschränkt oder ganz unterbunden werden.

Wesentlich ist es, die Anzahl der erforderlichen Sekundärzuweisungen pro Pubset so gering wie möglich zu halten.

EAMSIZ ist der Maximalwert an Allocation-Units innerhalb der Datei $TSOS.SYSEAM, die einem Anwender allein zur Verfügung stehen.

Richtwerte für die EAM-Systemparameter sind stark von der zu erwartenden Last abhängig. Die Werte für EAMMIN und EAMSEC sollten beide als Vielfache von 8 gewählt werden, weil dies eine optimale Anpassung an die interne Tabellenstruktur von EAM bewirkt.

Der Wert EAMMEM legt die Größe des Klasse-4-Speichers (in Units) fest, der für EAM benutzt wird. Er sollte ein Vielfaches von 8 sein. Die pubset-spezifische Festlegung erfolgt durch den Operanden `EAM=*PARAMETERS(VIRTUAL-MEMORY=...)` bei `/ADD-MASTER-CATALOG-ENTRY` bzw. `/MODIFY-MASTER-CATALOG-ENTRY`.

Dieser Bereich wird nur für den Home-Pubset angelegt und ist Teil der Datei `SYSEAM`. Zuerst wird der Klasse-4-Speicherbereich gefüllt und erst danach – wenn dieser voll ist – auf die Platte geschrieben.

Eine sinnvolle Nutzung (Beschleunigung von Übersetzungsläufen durch Einsparung von Ein-/Ausgaben) ist nur möglich, wenn ausreichend Hauptspeicher zur Verfügung steht. Andernfalls wird der Vorteil der Einsparung von physikalischen Ein-/Ausgaben auf die Datei `SYSEAM` durch erhöhtes Paging der Klasse-4-Speicherseiten kompensiert.

ETMFXLOW

Parametername	Werte-Bereich	STD-Wert
ETMFXLOW	127...256	256

Tasks mit einer externen Priorität größer oder gleich ETMFXLOW erhalten im Funktionszustand TU keinen Alterungszuschlag. Dadurch wird für diese Tasks die dynamische Einstellung der internen Priorität (siehe Abschnitt „Einführung in das PRIOR-Konzept“ auf Seite 223) abgeschaltet. Ein eventuell im Funktionszustand TPR gewonnener Prioritätszuwachs verfällt beim Übergang nach TU.

Tasks mit einer externen Priorität größer oder gleich ETMFXLOW eignen sich zur Definition einer Hintergrundlast. Für die Hauptanwendung(en) muss eine entsprechend große externe Prioritätsdifferenz gewählt werden. Der Einsatz dieser Funktion ist sehr sorgfältig durchzuführen und die Auswirkungen müssen überwacht werden.

JTABSMEM, JTSTDMEM, JTMAXMEM, JTSHMEM

Diese Systemparameter steuern auf SX-Servern gemeinsam die Hauptspeichernutzung für die Just-in-Time-Übersetzung von /390-Code durch die CISC-Firmware.
Die Bedeutung, Wertebereiche und das Zusammenwirken dieser Systemparameter sind im Abschnitt „Puffergröße der CISC-Firmware“ auf Seite 374 beschrieben.

L4SPDEF

Parametername	Werte-Bereich	STD-Wert
L4SPDEF	66...n	2500

Der Parameter L4SPDEF bestimmt die Reaktion des Systems auf eine beginnende Sättigung des Speicherplatzes auf den Public-Volumes. Es wird empfohlen, die Standardeinstellung zu übernehmen.

Der Wert ist nur gültig, solange keine andere pubset-spezifische Festlegung mit `/ADD-MASTER-CATALOG-ENTRY` bzw. `/MODIFY-MASTER-CATALOG-ENTRY`, Operand `ALLOCATION=*PARAMETERS(SATURATION-LEVEL4=...)`, erfolgt.

SSMAPRI, SSMASEC

Parametername	Werte-Bereich	STD-Wert
SSMAPRI	3...65535	24
SSMASEC	3...65535	24

Mit diesen Parametern wird für Systemausgabedateien die Größe der Primär- und Sekundärzuweisung festgelegt. Diese Parameter gelten für Dateien, die mit folgenden Kommandos angelegt werden:

```
/ASSIGN-SYSOUT
/ASSIGN-SYSLST
/ASSIGN-SYSOPT
```

Jede Erstbenutzung dieser Systemausgabedateien führt zum Einrichten einer katalogisierten Datei in der mit SSMAPRI und SSMASEC definierten Größe. Die Dateinamen sind:

```
S.OUT.tsn.yyyy-mm-dd.hhmmss.cnt
S.LST.tsn.yyyy-mm-dd.hhmmss.cnt
S.OPT.tsn.yyyy-mm-dd.hhmmss
```

SSMAPRI Primärzuweisung in PAM-Blöcken für die task-spezifischen SPOOLOUT-Dateien bzw. für umgewiesene Systemdateien, die mit einem `/ASSIGN-`...-Kommando erzeugt wurden.

SSMASEC Sekundärzuweisung in PAM-Blöcken für die task-spezifischen SPOOLOUT-Dateien bzw. für umgewiesene Systemdateien, die mit einem `/ASSIGN-`...-Kommando erzeugt wurden.

Die optimalen Werte für Primär- und Sekundärzuweisung dieser SPOOL-Ausgabedateien sind stark von der Art der Last abhängig. Liegen keine abweichenden Erfahrungen vor, sollten die Standard-Werte von jeweils 24 PAM-Blöcken beibehalten werden.

TEMPFILE

Parametername	Werte-Bereich	STD-Wert
TEMPFILE	C'#'/'@'/'NO'	C'NO'

Das Verfahren „temporäre Dateien“ (TEMPFILE) bietet den Anwendern die Möglichkeit, mit katalogisierten Dateien und/oder Jobvariablen zu arbeiten, die bei Angabe von `/EXIT-JOB` bzw. `/LOGOFF` vom System automatisch gelöscht werden.

Das Verfahren ist recht aufwändig, d.h. es wird viel Systemadressraum und CPU-Leistung benötigt. Dafür leistet es ein „automatisches Aufräumen“ von nicht benötigten Arbeitsdateien. Der Systembetreuer kann mit dieser Option bestimmen, ob das Verfahren angewendet werden darf und wie die Datei- und JV-Namen gekennzeichnet werden.

Ist die Option nicht versorgt, wird das Verfahren „temporäre Dateien“ nicht in das System eingebunden (Standard).

Der Katalogname für temporäre Dateien oder JVs lautet:

```
S.mmm.nnnn.dateiname
S.mmm.nnnn.jv-name
```

`mmm` wird ersetzt durch die Systemkennung (sysid) des Home-Pubsets
`nnnn` wird ersetzt durch die TSN der Task des Dateibenutzers

12.3 Puffergröße der CISC-Firmware

Folgende Systemparameter steuern auf SX-Servern die Hauptspeichernutzung für die Just-in-Time-Übersetzung von /390-Code durch die CISC-Firmware:

JTABSMEM

Parametername	Werte-Bereich	STD-Wert
JTABSMEM	0...65535	0

Mit diesem Parameter wird auf SX-Servern der maximale Speicherplatz für den JIT-Puffer festgelegt. Der Speicher wird resident angefordert und muss daher auf den Speicherausbau der Maschine abgestimmt sein.
Der Parameter ist mit 0 vorbelegt und die CISC-Firmware berechnet sich in diesem Fall den maximalen Speicherplatz zu: `MEMORY-SIZE * 40 %`.
Der berechnete Wert für `JTABSMEM` wird mit der Meldung `HJT0039` auf der Konsole protokolliert. Durch die Angabe eines Wertes von 1 - 65535 kann die Speichergröße auch fest vorgegeben werden. Der Parameter kann im laufenden Betrieb erhöht werden.

Bei Annäherung an den Grenzwert wird die Meldung `HJT0035` mit einem entsprechenden JIT-Memory-Saturation-Level ausgegeben. Bei Erreichen von Level 1 wird empfohlen, den Grenzwert zu erhöhen. Bei Erreichen von Level 2 wird dringend empfohlen den Grenzwert zu erhöhen, da sonst größere Performance-Einbußen zu erwarten sind.

Hinweis für VM2000
Auf einer VM bestimmt der Parameter `MIN-MEMORY-SIZE` indirekt die maximale Größe des residenten Hauptspeichers und begrenzte damit auch den globalen JIT-Puffer. Diese Beschränkung gilt für Gastsysteme ab BS2000/OSD V7.0 auf SX-Servern ab SX160 / SX100-D **nicht** mehr. Auf älteren Systemen wird bei Erreichen von `MIN-MEMORY-SIZE` die Meldung `HJT0034` ausgegeben. Im Standardfall (`MIN-MEMORY-SIZE` entspricht der Hauptspeichergröße der VM) ist nichts zu tun. Wird jedoch beim Einrichten der VM bzw. beim Vergrößern des Hauptspeichers der VM explizit ein anderer Wert für `MIN-MEMORY-SIZE` eingestellt, sollte dieser mindestens die Hälfte der `MEMORY-SIZE` betragen, so dass bei einem JIT-Puffer-Anteil von 40 % an der `MEMORY-SIZE` noch genügend Platz für andere CL1/3-Seiten bleibt. Falls größere DAB-Bereiche angelegt werden, sollte `MIN-MEMORY-SIZE` sogar noch höher gewählt werden, bzw. die Parameter BIG-PAGE-QUOTA und JTABSMEM explizit entsprechend herabgesetzt werden.
(Auf SX-Servern ab SX150 sind Big Pages zur Performance-Steigerung der CISC-Firmware verfügbar. Weitere Informationen dazu finden Sie im Handbuch „Systembetreuung“ [11]. Der Parameter BIG-PAGE-QUOTA (Parametersatz MEMORY) bestimmt seine Größe. Eine Verkleinerung dieser Einstellung ist normalerweise nicht zu empfehlen, kann aber mit `/MODIFY-MEMORY-PARAMETERS` erreicht werden, wenn dies für die VM-Speicher-Rekonfiguration im Einzelfall nötig ist.)

JTSTDMEM

Parametername	Werte-Bereich	STD-Wert
JTSTDMEM	1...65535	16

Dieser Parameter JTSTDMEM legt fest, wie viel JIT-Puffer das System jeder Task innerhalb des globalen JIT-Puffers maximal zur Verfügung stellt, sofern task-spezifisch keine andere Einstellung über `/MODIFY-DBL-DEFAULTS` erfolgt ist.

Die Standardgröße der task-spezifischen JIT-Puffer beträgt 16 MB. Da die CISC-Firmware nur so viel Speicher anfordert, wie zum Ablauf des aktuellen /390-Programms notwendig ist, wird empfohlen den STD-Wert nicht zu verändern. Bei Erreichen des Wertes JTSTDMEM wird die Meldung `HJT0032` ausgegeben, der task-spezifische JIT-Puffer zurückgesetzt und neu aufgebaut. Da die damit verbundene Performance-Minderung normalerweise gering ist, wird die Meldung nur in die CONSLOG-Datei ausgegeben.

Nur in sehr seltenen Fällen (z.B. bei besonders großem Working-Set-Bedarf einer Task) kann es vorkommen, dass eine Vergrößerung des JIT-Puffers sinnvoll ist.

Zur task-spezifischen Vergrößerung des JIT-Puffers muss die neue Größe mit folgendem Kommando angegeben werden:

```
/MODIFY-DBL-DEFAULTS SCOPE=*CMD-CALLS(CISC-COMPILATION=*YES(WORKSPACE=nn))
```

mit `nn` = Anzahl MB

Die Änderung wirkt für alle DBL-Aufrufe (`/START-`, `/LOAD-(EXECUTABLE-)PROGRAM`, BIND) der Task. Das Kommando muss in alle Enter-Jobs bzw. Prozeduren eingefügt werden, wenn dort Programme, die einen größeren JIT-Puffer benötigen, geladen werden.

JTMAXMEM

Parametername	Werte-Bereich	STD-Wert
JTMAXMEM	1...65535	128

Der Parameter JTMAXMEM legt den Maximalwert fest, der task-spezifisch über `/MODIFY-DBL-DEFAULTS` eingestellt werden kann.

JTSHMEM

Parametername	Werte-Bereich	STD-Wert
JTSHMEM	0...256	64

Legt auf SX-Servern fest, wieviel Speicherplatz JITSYS zur Ablage von Share-Kompilaten verwenden soll (in MB).

Share-Kompilate entstehen bei der Emulation von in Klasse-4-Speicher geladenen Subsystemen. Sind keine solchen Subsysteme vorhanden bzw. sollen diese nicht „shared“ übersetzt werden, kann mit JTSHMEM = 0 die Erzeugung von „shared“ Kompilaten verhindert werden. Der Wert JTSHMEM sollte in Abstimmung mit dem insgesamt zur Verfügung stehenden Klasse-3-Speicher gesetzt werden.

Die bei JTSHMEM angegebene Speichergröße wird bei Initialisierung von JITSYS sofort allokiert. Eine Änderung des Werts im laufenden Betrieb wird bis auf weiteres nicht unterstützt. Die Einstellung des Wertes kann nur in 4er-Schritten erfolgen, andere Werte werden auf die nächste 4-MB-Grenze aufgerundet.

Eine Änderung des Standardwertes von JTSHMEM sollte synchron zum Parameter BIGSHARE-SHRSIZE im Parametersatz MEMORY des Startup-Parameterservice erfolgen.

Zum Parameter SHXSIZE des Startup-Parameterservice besteht ein (indirekter) Zusammenhang:

Wenn SHXSIZE sehr groß gewählt und auch tatsächlich eine entsprechende Menge von Programmen „shared“ geladen wird, dann ist es sinnvoll, auch JTSHMEM zu erhöhen.

Abbildungen

Bild 1: Zeitdefinitionen bei Online-Anwendung 19

Bild 2: Zeitdefinitionen bei Batch-Verarbeitung 21

Bild 3: Kanal Typ FC 42

Bild 4: Anzahl ersetzbarer Kanäle Typ S durch einen Kanal Typ FC 44

Bild 5: Ablaufschema beim Lesen einer verschlüsselten Datei 107

Bild 6: Aktuelle Online- und Nearline-Peripherie der BS2000/OSD-Server 111

Bild 7: Aufbau des Dateikatalogs eines SM-Pubsets 179

Bild 8: Belegung des Seitenwechselbereichs 181

Bild 9: Ein-/Ausgabe-Abläufe bei einem Read-Cache 196

Bild 10: Ein-/Ausgabe-Abläufe bei einem Write-Cache 197

Bild 11: Ein-/Ausgabe-Abläufe bei einem Read-Write-Cache 198

Bild 12: BCAM-Zeiten 209

Bild 13: Anteil der TP-Anwendungen am Leistungsvermögen abhängig von der aktuellen Dehnung 252

Bild 14: Cache-Hierarchie bei einem Quadroprozessor mit First-Level Store-Through-Caches und Second-Level Store-In-Caches . . 254

Bild 15: BS2000-Funktionszustände (User-Task) 260

Bild 16: BS2000-Funktionszustände (System-Task) 260

Bild 17: Warteschlangenübergänge 283

Bild 18: Zeitlicher Ablauf einer Platten-Ein-/Ausgabe Read-Hit/Read-Miss beim Plattenspeichersystem Symmetrix 288

Bild 19: Komponenten der Produktlinie openSM2 293

Bild 20: Einsatz des Messmonitors SM2 295

Bild 21: Tuning-Ansätze bei hoher CPU-Auslastung 324
Bild 22: Zeitverhalten mehrstufiger Task-Konzepte 329
Bild 23: Ablauf beim Binden/Laden eines Programms/Produkts 346

Literatur

Die hier aufgelisteten Handbücher finden Sie auch

- im Internet auf unserem Manual-Server (URL: *http://manuals.ts.fujitsu.com*)
- auf der CD-ROM „BS2000/OSD SoftBooks“.
  Dort sind nahezu alle Handbücher und Readme-Dateien zur BS2000-Systemsoftware der aktuellsten BS2000/OSD-Version gespeichert.

Die Handbücher in gedruckter Form können gegen gesondertes Entgelt über das Internet unter *http://manualshop.ts.fujitsu.com* bestellt werden.

[1] **BCAM**
Benutzerhandbuch

[2] **BS2000/OSD-BC**
Dateien und Volumes größer 32 GB
Benutzerhandbuch

[3] **Business Server der SX-Serie**
Konzepte und Funktionen
Benutzerhandbuch

[4] **Business Server der SX-Serie**
Bedienen und Verwalten
Benutzerhandbuch

[5] **Business Server der SQ-Serie**
Bedienen und Verwalten
Benutzerhandbuch

[6] **DAB** (BS2000/OSD)
Disk Access Buffer
Benutzerhandbuch

[7] **BS2000/OSD-BC**
Dienstprogramme
Benutzerhandbuch

[8] **DRV** (BS2000/OSD)
Dual Recording by Volume
Benutzerhandbuch

[9] **BS2000/OSD-BC**
DVS-Makros
Benutzerhandbuch

[10] **BS2000/OSD-BC**
Einführung in das DVS
Benutzerhandbuch

[11] **BS2000/OSD-BC**
Einführung in die Systembetreuung
Benutzerhandbuch

[12] **FDDRL** (BS2000/OSD)
Benutzerhandbuch

[13] **HIPLEX MSCF** (BS2000/OSD)
BS2000-Rechner im Verbund
Benutzerhandbuch

[14] **HNC-IV 91853**
High-Speed Net Connect
Benutzerhandbuch

[15] **HSMS / HSMS-SV** (BS2000/OSD)
Hierarchisches Speicher Management System (Band 1 und 2)
Benutzerhandbuch

[16] **BS2000/OSD-BC**
Kommandos
Benutzerhandbuch

[17] **LEASY** (BS2000/OSD)
Programmschnittstelle und Konzepte
Benutzerhandbuch

[18] **BS2000/OSD-BC**
Migration Guide
Benutzerhandbuch

[19] **openSM2** (BS2000/OSD)
Software Monitor
Benutzerhandbuch

[20] **openUTM**
Konzepte und Funktionen
Benutzerhandbuch

[21] **openUTM** (BS2000/OSD, UNIX, Windows)
Anwendungen administrieren
Benutzerhandbuch

[22] **openUTM** (BS2000/OSD, UNIX, Windows)
Anwendungen generieren
Benutzerhandbuch

[23] **openUTM** (BS2000/OSD)
Einsatz von openUTM-Anwendungen unter BS2000/OSD
Benutzerhandbuch

[24] **PCS** (BS2000/OSD)
Performance Control Subsystem
Benutzerhandbuch

[25] **ROBAR** (BS2000/OSD, Solaris, Linux)
Steuerung von MBK-Archivsystemen
Benutzerhandbuch

[26] **SDF** (BS2000/OSD)
SDF-Verwaltung
Benutzerhandbuch

[27] **SESAM/SQL-Server** (BS2000/OSD)
Datenbankbetrieb
Benutzerhandbuch

[28] **SHC-OSD / SCCA-BS2**
Storage Management für BS2000/OSD
Benutzerhandbuch

[29] **SM2-PA** (BS2000/OSD)
SM2-Programmanalysator
Benutzerhandbuch

[30] **SPACEOPT** (BS2000/OSD)
Optimierung und Reorganisation von Platten
Benutzerhandbuch

[31] **BS2000/OSD-BC**
Systeminstallation
Benutzerhandbuch

[32] **BS2000/OSD-BC**
System Managed Storage
Benutzerhandbuch

[33] **VM2000** (BS2000/OSD)
Virtuelles Maschinensystem
Benutzerhandbuch

Stichwörter

$SYSJS 221
$VMCONS 157
/390-Code 31, 33, 371
/390-Modus 32

A
ADM-PFA-Caching 36, 195, 199
Adressraum 161
affine Tasks 255
AINF (Makro) 368
Änderungen 14
Antwortzeit 18, 19
  Optimierung 208
  Optimierung mit PCS 245
Anwender-Software 337
  Bearbeitungsmodus 343
  performantes Laden 345
  Zugriffsmethode 337
Anwenderdateien 192
Anwenderprogramme 17
Anzahl Terminals (K) 22
ARCHIVE 113
Auftrag 21
Auslastung von Terminals (U) 23
AutoDAB 199, 314
Autolink 348

B
Batch-Auftrag 219
  Auswahlparameter 217
  im XCS-Verbund 218
Batch-Betrieb 27
Batch-Last 27
Batch-Task 263
Batch-Verarbeitung 21
BCAM 208, 215
BCAM-Pool 210, 215
BCAM-Transportsystem 19, 20
Bedienzeit
  Hardware 289
  Software 289
Belegung 257
Benutzeradressraum 161
Benutzerkatalog 164
Betriebsarten von Platten 163
Betriebsmittel
  CPU 265
  Hauptspeicher 265
Betriebsmittelauslastung 293, 306
Betriebsmittelbelegung 257
Betriebsmittelreservierung 257
Betriebsmittelverbrauch 307
Bibliothek 349
Blockgröße 71
BMTNUM (Systemparameter) 175, 178, 363
BTAM (Zugriffsmethode) 337
Bucket 211
Buffer Management Tables 363

C
C-Programme 352
C/C++ 32
C40 27
Cache 57, 58, 59, 201, 352
Cache-Hit 196
Cache-Miss 196
Caching
  ADM-PFA 195
  User-PFA 195
Catalog Management System 175

CATBUFR (Systemparameter) 178, 363
CentricStor 126
Chained-IO 337
CISC-Firmware 31, 33, 371, 374
CONSDDE7 (Systemparameter) 364
Control-Volume-Set 179
Controller 57, 59
COPE 335
COSMOS 334
CPU
  Auslastung bei Multiprozessor-Systemen 30
  Leistung 27
  Leistungssteigerung 28
  Verfügbarkeit 28
  Verwaltung 279
  Zeit bei Multiprozessor-Systemen 29
CPU-Pool 144
CPU-Quote 141, 152

D
DAB, siehe Disk Access Buffer
Data-Management 159
Datei 307
  Anwenderdatei 192
  Extent 194
  Reorganisation 194
  schließen 344
  SJMSFILE 220
  SYSEAM 185, 370
  temporär 373
  verschlüsselt 106
  Zugriffe 344
Dateikatalog
  Formate 175
  SF-Pubset 175
  SM-Pubset 179
Datensicherung
  Differenzsicherung 112
  FDDRL 116
  HSMS/ARCHIVE 113
  logisch 112
  physikalische 112
  Vollsicherung 112
  Volumen 112
Datenträgerüberwachung 257
DCAM-Schnittstelle 19
DEFLUID (Systemparameter) 365
Dehnfaktor 25
Dehnung 25
Denkzeit 19, 22, 25
Desaster Tolerant Disk System 63
DESTLEV (Systemparameter) 365
Dialog-Task 263
Dialoganwendung 219
Dialogbetrieb 18, 182, 353
Differenzsicherung 112
Directory, HSMS 113
Disk Access Buffer 36, 165, 307, 314, 344, 352
DIV (Zugriffsmethode) 341
DMMAXSC (Systemparameter) 366
DMPRALL (Systemparameter) 366
DMSCALL (Systemparameter) 366
Dual Recording by Volume 163, 167
Durchsatz 15
  Optimierung mit PCS 245
  Steigerung bei Multiprozessor-Systemen 29
Durchsatzrate 21

E
EACTETYP (Systemparameter) 189, 369
EAMMEM (Systemparameter) 186, 370
EAMMIN (Systemparameter) 186, 370
EAMSEC (Systemparameter) 370
EAMSIZ (Systemparameter) 370
Ein-/Ausgabe 286, 337
Ein-/Ausgabe-Unterbrechung 262
Engpass-Analyse mit SM2 303
ESD-Information 351
ETERNUS CS 126
ETMFXLOW (Systemparameter) 371

F
F1-Kennsatz 367
FASTPAM (Zugriffsmethode) 338
FC-Anschluss 125
FC-Peripherie 40, 45, 48
FDDRL 116

FibreCAT 126, 194
Replikationsfunktionen 65
Fragmentierung 194
Funktionszustand 259
MEH 259
SIH 31, 259
TPR 31, 259
TU 31, 259

G
Gastsystem 139, 151
RPF 151
Systembetreuung 154
GB 15
Gerät 40
Geräteverwaltung 257
Gigabit Ethernet 96, 97, 98, 101, 102
Global Storage siehe Globalspeicher
Globalspeicher 36, 195, 207, 309
Caching 195
GSMAN 207
GSVOL 36, 195, 207

H
Hardware-Bedienzeit 58, 289
Hauptspeicher 35, 195, 265, 267, 273, 302
Caching 195
Seitenverwaltungs-Algorithmus 277
Hauptspeichernutzung 35
HIPERBATCH 204
HIPERFILE-Konzept 36, 192, 195, 314
Cache-Hit 196
Cache-Hit-Rate 196
Cache-Miss 196
Caching-Modi 196
Read-Cache 196
Read-Write-Cache 198
Write-Cache 197
HIPLEX-Verbund 36
HSMS 113
HSMS-Directory 113

I
I/O-Prozessoren 28
I/O-Zeit 58
ICMX-Schnittstelle 20
IDCAM-Schnittstelle 20
Inbound Flow Control 210
Interne Platten (SX-Server) 47
ISAM (Parametersatz) 114
ISAM (Zugriffsmethode) 339
ISAM-Pool 307, 313, 340
ITIAM-Schnittstelle 19, 20

J
JIT-Puffer 31, 374
JIT390 31
JMU 220
Job 21
Job-Klasse 217
Job-Management 159, 217
Job-Scheduler 221
Job-Scheduling-Strategien 217
Job-Streams 221
JTABSMEM (Systemparameter) 371, 374
JTMAXMEM (Systemparameter) 371, 375
JTSHMEM (Systemparameter) 371, 376
JTSTDMEM (Systemparameter) 371, 375
Just-In-Time-Übersetzung 31, 371

K
Kanal 40
Typ FC 41, 57, 125
Typ S 40, 57, 125
Kanalperipherie 40
Katalogintensität 193
Katastrophe 63
Kategoriesteuerung 225
KB 15
KDCFILE 213
Klasse-2-Systemparameter
siehe Systemparameter 362
Klassen-Scheduler 222
Krypto-Box 106
Krypto-CPU 106

L
L4MSG (Systemparameter) 369
L4SPDEF (Systemparameter) 372
LAN-Anschluss
S-Server 95
SQ-Server 102
SX-Server 101
Langzeitmessung mit SM2 296
Lastanalyse 229
Lasttyp 71
Lastverhalten 293
LEASY 341
Leistungserwartungen 22, 24
für Online-Betrieb 26
Leistungswerte (Beispiele) 27
LLM-Objekte 347, 351
logische Datensicherung 112
LTO 126
LUN 60

M
Maschinenfehler-Unterbrechung 262
Maßeinheit 15
MB 15
MBK-Archivsystem
FibreCAT 126
Scalar 126
MEH (Funktionszustand) 259
Mehrrechnerbetrieb 166
Meldungsdateien 187
Meldungsgewicht 187
Mess-System openSM2 293
Messmonitor 294, 295
Micro Time Slice 281
Migration
von S-Servern zu SX-Servern 50
MIN-MEMORY-SIZE (VM2000-Parameter) 374
Mirroring, siehe Datenspiegelung
Monoprozessor 29
MRS-Katalog 175
MSGCENTL (Systemparameter) 191, 369
MSGCENTN (Systemparameter) 191, 369
MSGDLAM (Systemparameter) 369
MSGFILii (Systemparameter) 187, 369
MSGMAKER 187
MSGNOFL (Systemparameter) 187, 369
Multiprozessor-Systeme 28
CPU-Auslastung 30
CPU-Zeit 29
Durchsatz 29

N
Nearline-Peripherie 111
Netzanalyse 208
Netzlaufzeit 19, 208, 210
Netzqualität 208
Nucleus Device Management 257

O
OLTP-Last 27
OLTP-Transaktion 208
Online-Anwendung 18
Online-Peripherie 111
openCRYPT 106
openFT 106
openSM2 293
openSM2, siehe auch SM2
openUTM 208, 211
Overrun-Intervall 211, 215

P
Paging Area 180, 301
Paging Load Control Function 275
Paging-Rate 319
Parallel Access Volume 69, 287, 291, 315, 318
Parallel HIPLEX-Verbund 207
Parallelität 113
Parameterdatei SYSPAR.BS2.version 362
Parametersatz ISAM 114
Parametersatz SYSOPT-CLASS2 362
Partition 31
PCI-Controller 101, 102
PCS 156
PCSDEFINE (Dienstprogramm) 248
Performance Control System 243, 298
Performant File Access 203
PFA-Cache-Bereiche 36
PFA-Caching 205

physikalische Datensicherung 112
PKCS#11 106
PLAM-Bibliotheken 347
Platten, Betriebsarten 163
Plattenspeichersystem
DMX 57, 73, 91, 132
DMX-3 73, 91
Eigenschaften 57
FibreCAT 57, 86
Symmetrix 8000 57, 81
V-Max 57, 73, 91
Plattenspiegelung 163, 168
Preemption 272
Preemption Control Function 274
PRIOR 223, 298, 320
Lastanalyse 229
Scheduling-Algorithmus 256
Priorität 266
Prioritäten-Steuerung 223
Prioritätenvergabe 240
Private-Slices 347
Private-Volume 163, 166, 257
Problemanalyse 293
Programm-Unterbrechung 261
Public-Slices 347
Public-Volume 163, 164
Pubsets 164

R

RAID-Gruppe 60
RAID-Level 61
Rate Adaption 128
Read Ahead 58
Read-Cache 196
Read-Hit 58
Read-Miss 58, 59
Read-Write-Cache 198
Referenzmaschine C40-F 27
Rekonfiguration 257
Relativer Performance Faktor 27
Remote System Call 70
Remote-Cache 64
Reorganisation 194
Replikation 63
Reports 297
residenter Hauptspeicher 162

S

S-Connection Director 40
SAM (Zugriffsmethode) 339
SCA (Speed Catalog Access) 364
Scalar 126
Scheduling
feste CPU-Zuordnung 142
Zeitscheibe 140
Scheduling-Algorithmus (PRIOR) 256
Schwellwert 212
Seitenwechselbereich 180
Server-Wechsel 50
SF-Pubset 163, 164, 170
Shared Code 350
Shared-Private-Disk 163, 166, 344
Shared-Private-Volume 258
Shared-Pubset 165, 344
Sicherungsvolumen 112
SIH (Funktionszustand) 259, 311
Single Recording by Volume 167
SM-Pubset 163, 165, 171
SM2
COSMOS 334
Engpass-Analyse 303
Leistungsbedarf 333
Messmonitor 294, 295
Messprogramme 19, 243
Reports 297
Ressourcen-Bedarf 333
Snapshot 64, 65
SNMP 208
SOCKETS-Schnittstelle 20
Software-Bedienzeit 289
Space Control 185
SPACEOPT 194
SPARC64-Modus 32
Speed Catalog Access 168
SRDF 63
SSMAPRI (Systemparameter) 372
SSMASEC (Systemparameter) 372
Stand-by-Pubset 170

Standard-Benutzerkennung 365
Standard-Job-Scheduler 221
Standard-Katalogkennung 365
Standard-Volume-Label 257
Storage-Klasse 171, 172
Storage-Services 171
Streaming-Grenze 128
Stromausfall 58
Subsysteme 160
SVC 261, 307, 321
Symmetrix 163, 168, 185, 194, 289, 308, 315
  Host-Komponente 63
  TimeFinder 64
Symmetrix Remote Data Facility 63, 64, 319
SYSEAM 185, 370
SYSOPT-CLASS2 (Parametersatz) 362
SYSPAR.BS2.version (Parameterdatei) 362
System Managed Storage 165
System Service Slice 275
System Working Set 277
System-Job-Scheduler 221
System-Task 224, 264
Systemadressraum 161
Systemdateien 174
Systemkern 159
Systemmeldungen 189
Systemparameter
  BMTNUM 175, 178, 363
  CATBUFR 178, 363
  CONSDDE7 364
  DEFLUID 365
  DESTLEV 365
  DMMAXSC 366
  DMPRALL 366
  DMSCALL 366
  EACTETYP 189, 369
  EAMMEM 186, 370
  EAMMIN 186, 370
  EAMSEC 370
  EAMSIZ 370
  ETMFXLOW 371
  JTABSMEM 371, 374
  JTMAXMEM 371, 375
  JTSHMEM 371, 376
  JTSTDMEM 371, 375
  L4MSG 369
  L4SPDEF 372
  MSGCENTL 191, 369
  MSGCENTN 191, 369
  MSGDLAM 369
  MSGFILii 187, 369
  MSGNOFL 187, 369
  SSMAPRI 372
  SSMASEC 372
  TEMPFILE 373
Systemsoftware 17
Systemüberwachung 296
Systemumgebung 159, 160

T

TAC-Klassen 214
TANGRAM 254, 279
Task 263, 265, 307
  Preemption 272
  Warteschlangen 223, 282
Task In Control 282
Task-Kategorien 224
Task-Management 159, 223
Task-Prioritäten 219, 226
Taskgruppen 255
TCP-Transportservice 20
TEMPFILE (Systemparameter) 373
temporäre Dateien 373
Terminal
  Anzahl (K) 22
  Auslastung (U) 23
  Wirkungsgrad (W) 22
TimeFinder 64
TP-Anwendung 219
TP-Betrieb 18, 27, 182, 208, 353
TPR (Funktionszustand) 259
Transaktion 18
Transaktionsbetrieb, siehe TP-Betrieb
Transaktionsrate 18
Transaktionszeit 18, 19, 22, 25
Trend-Abschätzung 293
TSOSCAT 164, 175, 363
TU (Funktionszustand) 259

U
Übertragungsrate 15
Umstieg
auf SX- oder SQ-Server 50
Unterbrechung 259
UPAM (Zugriffsmethode) 337
User Shared Memory 350
User-PFA-Caching 195, 203
User-Task 263

V
verschlüsseln 106
Verschlüsselungsverfahren 108
Verweilzeit 21
virtuelle Maschine (VM) 139
VM2000 139, 298, 306
$VMCONS 157
Anzahl Gastsysteme 151
CPU-Leistung 140
CPU-Pool 144
CPU-Quote 141, 152
Hauptspeicher 146
IO-PRIORITY 149
Overhead 139
PCS 156
Peripherie 147
RPF 151
Scheduling 140
Systembetreuung 154
VM-Gruppe 143
Vollsicherung 112
Volume, logisch 66
Volume-Set 171, 173, 179

W
Waiting Time 276
Warteschlangen 223
Wirkungsgrad für Terminal (W) 22
Working-Set-Bedarf 182, 232
Write-Cache 197
Write-Hit 58

X
XCS-Verbund 218

Z
Zeitdefinitionen
bei Batch-Auftrag 21
bei Online-Anwendung 19
Zeitgeber-Unterbrechung 262
Zugriffsmethode 337
BTAM 337
Datenbanken 341
DIV 341
FASTPAM 338
HASH 340
ISAM 339
SAM 339
UPAM 337
Zugriffssysteme 163